



HAL
open science

Stratégies de vision active pour la reconnaissance d'objets

Joseph Defretin

► **To cite this version:**

Joseph Defretin. Stratégies de vision active pour la reconnaissance d'objets. Mathématiques générales [math.GM]. École normale supérieure de Cachan - ENS Cachan, 2011. Français. NNT : 2011DENS0047 . tel-00696044

HAL Id: tel-00696044

<https://theses.hal.science/tel-00696044v1>

Submitted on 10 May 2012

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

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



ÉCOLE NORMALE SUPÉRIEURE DE CACHAN
ÉCOLE DOCTORALE SCIENCES PRATIQUES

THÈSE

présentée pour obtenir le grade de
docteur de l'École Normale Supérieure de Cachan

Spécialité mathématiques

par

Joseph DEFRETIN

Centre de Mathématiques et de leurs Applications (CMLA), ENS-Cachan
Département Traitement de l'Information et Modélisation, ONERA

STRATÉGIES DE VISION ACTIVE POUR LA
RECONNAISSANCE D'OBJETS

Thèse soutenue le 23 novembre 2011 devant le jury composé de :

Mr. JACQUES BLANC-TALON	DGA	Examineur
Mr. FRANÇOIS CHARPILLET	INRIA	Rapporteur
Mr. MATHIEU CORD	Université Paris VI	Président
Mr. STÉPHANE HERBIN	ONERA	Encadrant
Mr. SIMON LACROIX	CNRS	Rapporteur
Mr. GUY LE BESNERAIS	ONERA	Encadrant
Mr. NICOLAS VAYATIS	ENS-Cachan	Directeur



REMERCIEMENTS

CES trois années de thèse, qui ont été financées par la Direction Générale de l'Armement, ont été partagées entre le Département Traitement de l'Information et Modélisation (DTIM) de l'ONERA et le Centre de Mathématiques et de Leurs Applications (CMLA) de l'ENS-Cachan. Je remercie Bernard Lécussan, Directeur du DTIM, Gilles Foulon, le Directeur adjoint à Palaiseau, et Frédéric Pascal, Directeur du CMLA, pour m'avoir accueilli au sein de leurs équipes.

Je tiens à remercier Stéphane Herbin et Guy Le Besnerais pour m'avoir proposé ce sujet de thèse et pour m'avoir encadré.

Je remercie sincèrement Nicolas Vayatis pour avoir accepté de diriger ma thèse, pour son aide et son soutien, et qui, par son exigence, m'a permis de prendre conscience de la nécessité de qualité dans un travail de recherche.

Simon Lacroix et François Charpillet m'ont fait l'honneur de rapporter cette thèse. Je les remercie pour l'intérêt qu'ils ont porté à mes travaux, ainsi que pour leurs suggestions et le recul qu'ils m'ont permis de prendre. Je remercie aussi Jacques Blanc-Talon, ainsi que Matthieu Cord qui a accepté de présider mon jury.

Une thèse a beau être un travail personnel, elle ne se fait jamais seul. La bonne ambiance qui m'entourait a beaucoup contribué à concrétiser ce travail. Je remercie l'ensemble des membres du DTIM qui y ont été pour beaucoup. Merci particulièrement à Françoise pour son accueil et sa bonne humeur infaillible au secrétariat, à Martial pour ses talents reconnus de cuisinier (et ses talents inattendus d'admin réseau;-)), à Valérie pour son aide et sa patience en Anglais. Je ne peux bien sûr pas oublier les thésards, Aurélien, Christophe, Pauline, Guillaume, Laure, Paul, Thibaut, Jeff, et les ex-thésards, Anne-Marie, Evangeline, Antoine et Walid pour les bons moments passés ensemble.

Je remercie également les membres du CMLA, en particulier Micheline, Véronique et Virginie pour leur disponibilité et leur grande efficacité au secrétariat, Pascal pour son aide informatique, ses coups de gueule et son humour bien souvent malgré lui, et les thésards Emile, Nicolas et Antoine pour la bonne ambiance dans le bureau.

Ce travail est également le fruit de rencontres et de collaborations. Je remercie pour cela Hélène Piet Lahanier pour l'intérêt qu'elle a pu porter à mes travaux et pour son aide. C'est également avec beaucoup de plaisir que j'ai travaillé avec Julien Marzat et Nicolas Baskiotis. Merci aussi à Jonathan Guinet pour ses relectures minutieuses et efficaces de ce manuscrit, et à Mathieu Balesdent pour ses conseils lors des répétitions de ma soutenance.

Je n'oublie pas non plus les thésards du DCPS de l'ONERA, avec qui la bonne ambiance est également assurée dans le département où je travaille aujourd'hui.

Je tiens enfin à remercier ma famille et mes amis pour leur soutien et leur affection.

TABLE DES MATIÈRES

TABLE DES MATIÈRES	vi
LISTE DES FIGURES	ix
LISTE DES TABLES	xi
INTRODUCTION	1
1 RECONNAÎTRE LES OBJETS : UN BESOIN D'ORIGINE PHYSIOLOGIQUE	1
2 VISION PASSIVE <i>vs.</i> ACTIVE	2
3 ORIGINES ET APPLICATIONS DE LA VISION ACTIVE PAR ORDINATEUR	2
4 CARACTÉRISTIQUES D'UN SYSTÈME DE VISION ACTIVE	3
5 VISION ACTIVE POUR LA RECONNAISSANCE	4
Contexte	4
Revue de la littérature et motivations	5
6 CONTRIBUTIONS	7
7 ORGANISATION GÉNÉRALE DU DOCUMENT	8
PARTIE 1 : État de l'art et outils mathématiques	13
1 CLASSIFICATION SUPERVISÉE POUR LA RECONNAISSANCE	13
PLAN DU CHAPITRE	14
1.1 INTRODUCTION	14
1.2 APPRENTISSAGE SUPERVISÉ	15
1.2.1 Hypothèses	15
1.2.2 Classification binaire : rappels théoriques	16
1.2.3 Modèles génératifs <i>vs.</i> discriminatifs	19
1.2.4 Extension au cas multi-classes	22
1.3 REPRÉSENTATION DES OBJETS POUR LA RECONNAISSANCE	24
1.3.1 Perception, invariance et reconnaissance	24
1.3.2 Modélisation 2D	25
1.3.3 Modélisation 3D	30
1.3.4 Réduction de la dimension et sélection de caractéristiques	32
CONCLUSION	34
2 FORMALISME POUR UNE RECONNAISSANCE ACTIVE	35
PLAN DU CHAPITRE	36
2.1 INTRODUCTION	36
2.2 CADRE PROBABILISTE POUR LA RECONNAISSANCE	37
2.2.1 Reconnaissance statistique : approche bayésienne	37
2.2.2 Autres travaux sur la reconnaissance statistique bayésienne	38
2.3 INTÉGRATION SÉQUENTIELLE DE L'INFORMATION	38
2.3.1 Intégration bayésienne	39
2.3.2 Autres approches pour l'intégration	40
2.4 RECONNAISSANCE ACTIVE	41

2.4.1	Critère d'arrêt	42
2.4.2	Algorithme	42
2.4.3	Critères de performance d'une stratégie de planification	43
	CONCLUSION	44
3	MODÉLISATION DES OBJETS	45
	PLAN DU CHAPITRE	46
3.1	CHOIX D'UNE MODÉLISATION POUR UNE RECONNAISSANCE ACTIVE DE VÉHICULES	46
3.1.1	Détection	46
3.1.2	Description et modélisation	47
3.2	CONSTRUCTION DES MODÈLES	48
3.2.1	Incertitude sur les modalités d'acquisition	48
3.2.2	Modélisation de densité	49
3.3	DISPOSITIF EXPÉRIMENTAL	52
3.3.1	Constitution de la base de données	52
3.3.2	Description des objets	52
3.3.3	Détermination de la complexité optimale des modèles	53
	CONCLUSION	55
	 PARTIE 2 : Planification des conditions de prise de vue	 59
4	DE LA PLANIFICATION PAR L'AMBIGUÏTÉ VERS UN CRITÈRE ADAPTATIF	59
	PLAN DU CHAPITRE	60
4.1	REVUE ET LIMITATIONS DES APPROCHES EXISTANTES	60
4.1.1	Rappels de l'état de l'art	60
4.1.2	L'entropie comme mesure de l'ambiguïté	61
4.1.3	Planification par entropie en ligne et hors ligne	62
4.1.4	Limites de l'entropie pour la planification	63
4.2	PLANIFICATION ADAPTATIVE	64
4.2.1	Adaptation en ligne de la planification	64
4.2.2	Algorithme de reconnaissance active avec critère adaptatif	65
4.3	ÉVALUATIONS	66
4.3.1	Dispositif expérimental et modélisation des objets	66
4.3.2	Comparaison entre l'entropie moyenne et l'entropie conditionnelle	68
4.3.3	Critère adaptatif. Évaluation et influence du paramètre α	71
4.3.4	Comparaison entre les critères adaptatif et max-adaptatif	72
4.4	DISCUSSIONS	75
	CONCLUSION	76
5	PLANIFICATION AVEC UN BUDGET D'OBSERVATIONS LIMITÉ	79
	PLAN DU CHAPITRE	80
5.1	INTRODUCTION	80
5.2	FORMULATION DU PROBLÈME	82
5.2.1	Apprentissage par renforcement	82
5.2.2	Apprentissage par renforcement pour la planification des CPDV	84
5.3	DÉTERMINATION DE LA POLITIQUE OPTIMALE : MÉTHODES DE RÉFÉRENCE	85
5.3.1	Q-learning	86
5.3.2	Programmation dynamique	88
5.4	PROCESSUS GAUSSIENS ET APPRENTISSAGE ACTIF	90
5.4.1	Rappels sur les processus gaussiens	90
5.4.2	Q-learning et processus gaussiens	92
5.4.3	Programmation dynamique et processus gaussiens	95
5.5	ÉVALUATIONS	96

5.5.1	Mise en œuvre du Q-learning	97
5.5.2	Mise en œuvre de la programmation dynamique	101
5.6	DISCUSSIONS	102
	CONCLUSION	105
PARTIE 3	Classification supervisée pour la reconnaissance active	109
6	RECONNAISSANCE ACTIVE HIÉRARCHIQUE	109
	PLAN DU CHAPITRE	110
6.1	MOTIVATIONS ET TECHNIQUES D'INTERPRÉTATION MULTI-ÉCHELLES	110
6.1.1	Rappels de l'état de l'art	110
6.1.2	Limites d'une reconnaissance active pleine échelle pour un nb. de classes élevé	111
6.2	RECONNAISSANCE ACTIVE HIÉRARCHIQUE	112
6.2.1	Extraction de la hiérarchie de classification	112
6.2.2	Cadre de discernement dynamique	114
6.3	PLANIFICATION ADAPTATIVE MULTI-ÉCHELLES	115
6.3.1	Hiérarchie de planification	115
6.3.2	Critères de planification multi-échelles	116
6.4	ÉVALUATIONS	119
6.4.1	Dispositif expérimental et modélisation des objets	119
6.4.2	Apport de l'interprétation multi-échelles	121
6.4.3	Apport de la classification hiérarchique pour l'interprétation pleine échelle .	122
6.4.4	Résumé : choix du seuil P_{\min}	127
6.5	DISCUSSIONS	127
	CONCLUSION	128
7	CLASSIFICATION D'ASPECT ET ADAPTATION DE DOMAINE	129
	PLAN DU CHAPITRE	130
7.1	ESTIMATION DE LA POSE DES OBJETS	130
7.1.1	Rappels de l'état de l'art	130
7.1.2	Classification d'aspect	132
7.1.3	Évaluations	137
7.2	ADAPTATION DE DOMAINE DU CLASSIFIEUR	140
7.2.1	Origines de l'apprentissage transféré	141
7.2.2	Principe de l'adaptation de domaine et travaux connexes	141
7.2.3	Comparaison de la structure des données non annotées	142
7.2.4	Évaluation de la distance entre deux distributions	144
7.2.5	Résumé de la procédure	145
7.2.6	Évaluations	146
7.3	DISCUSSIONS	153
	CONCLUSION	156
	CONCLUSION ET PERSPECTIVES GÉNÉRALES	157
A	CONSTRUCTION DE LA BASE DE DONNÉES DE VÉHICULES	163
A.1	DESCRIPTION DU DISPOSITIF D'ACQUISITION	163
A.2	CALIBRATION DE LA CAMÉRA	163
A.3	ACQUISITION ET ANNOTATION DES IMAGES	166
B	PROCÉDURE DE DASVM	169
B.1	PHASE 1 : INITIALISATION	169
B.2	PHASE 2 : ADAPTATION DE DOMAINE ITÉRATIVE	169
B.3	PHASE 3 : CRITÈRES D'ARRÊT	170

BIBLIOGRAPHIE	171
NOTATIONS	187
COMMUNICATIONS SCIENTIFIQUES	191
*	

LISTE DES FIGURES

1	Exemple de parcours visuels libres d'une image.	3
2	Boucle d'action et de traitement de l'information perçue en vision active . . .	4
3	Illustration du besoin de la vision active	6
1.1	Principe de la classification par apprentissage supervisé	16
1.2	Les différents niveaux d'erreur de généralisation du classifieur.	18
1.3	Erreurs d'apprentissage et de test	19
1.4	Principe de la validation croisée pour l'estimation de l'erreur de test	19
1.5	Approches générative et discriminative	21
1.6	Illustration de la variance inter-classes et intra-classe	25
2.1	Éléments constitutifs de la prise de décision séquentielle.	38
2.2	Boucle fermée de reconnaissance active	42
2.3	Les différents critères de performance d'une stratégie de planification	44
3.1	Détection, description, et reconnaissance des véhicules.	47
3.2	Illustration de l'estimation de densité par mélange gaussien	51
3.3	Base de données utilisée pour les validations expérimentales	53
3.4	Représentation des images par le descripteur GLOH.	53
3.5	Dispositif expérimental utilisé pour la reconnaissance active	54
3.6	Variance expliquée par les composantes principales des descripteurs GLOH	54
3.7	Critères BIC, AIC, et critère de performance sur les données test	55
4.1	Source, récepteur, et modélisation du canal d'information.	62
4.2	Évolution de l'entropie d'une distribution	63
4.3	Illustration de la surjectivité de la mesure d'entropie	64
4.4	Base de données utilisée pour la reconnaissance.	67
4.5	Carte d'entropie moyenne calculée sur l'ensemble des modèles de la base	69
4.6	Cartes d'entropies conditionnelles	70
4.7	Comparaison entropie moyenne/conditionnelle : $Aire_T$ et $Perf_{max}$	70
4.8	Comparaison entropie moyenne/conditionnelle : nb. de vues et perf. moyenne	70
4.9	Cartes de planification par critère adaptatif ($\alpha = 1$)	72
4.10	Critère adaptatif : $Aire_T$ et $Perf_{max}$	72
4.11	Critère adaptatif : perf. moyenne et nb. de vues	73
4.12	Cartes de planification par critère max -adaptatif ($\alpha = 1$)	74
4.13	Critères adaptatif/ max -adaptatif : $Aire_T$ et $Perf_{max}$	74
4.14	Critères adaptatif/ max -adaptatif : nb. de vues et perf. moyenne	74
4.15	Critère max -adaptatif : performances par classe	75
4.16	Critère max -adaptatif : taux de rejet et matrice de confusion	75
4.17	Exemple de reconnaissance active	76

5.1	Boucle d'interaction entre l'agent et son environnement	83
5.2	Boucle fermée de reconnaissance active avec apprentissage par renforcement	84
5.3	Illustration de l'échantillonnage impliqué dans le Q-learning	88
5.4	Procédure de récursion par programmation dynamique	89
5.5	Échantillonnage actif par processus gaussiens	92
5.6	Illustration de l'algorithme EGO	95
5.7	Approximation de la fonction $Q(\cdot)$ par itération de la politique (ϵ -greedy) .	99
5.8	Approximation de la fonction $Q(\cdot)$ avec EGO et interpolation par krigeage .	99
5.9	RMSE entre la fonction $Q(\cdot)$ réelle et les fonctions d'approximation obtenues	100
5.10	Résultats pour le Q-learning - Performance de reconnaissance cumulée . . .	101
5.11	Résultats pour le Q-learning - Δ_{Aire_T}	101
5.12	Exemple de reconnaissance active avec GPQL-2	102
5.13	Résultats pour la prog. dynamique - Perf. de reconnaissance cumulée	103
5.14	Résultats pour la prog. dynamique - Δ_{Aire_T}	103
5.15	Exemple de reconnaissance active avec DPEGO	104
5.16	Comparaison des performances cumulées de reconnaissance	105
6.1	Évolution des critères de planification en fonction du nombre de classes . . .	113
6.2	Graphe acyclique orienté pour la classification multi-échelles	114
6.3	Graphe acyclique orienté pour une planification multi-échelles des CPDV . .	117
6.4	Bases de données utilisées pour la reconnaissance avec 4, 8 et 12 classes. . . .	119
6.5	Planification adaptative multi-échelles : $Aire_T$	120
6.6	Planification adaptative multi-échelles : perf. maximale	120
6.7	Planification adaptative multi-échelles : nb. de vues	122
6.8	Planification adaptative multi-échelles : perf. cumulée	123
6.9	Planification adaptative multi-échelles : $Aire_T$	124
6.10	Planification adaptative multi-échelles : perf. maximale	124
6.11	Planification adaptative multi-échelles : nb. de vues	125
6.12	Planification adaptative multi-échelles : perf. cumulée	125
6.13	Exemple de reconnaissance active hiérarchique avec une planification AME .	126
6.14	Résumé : évolution des critères de performance	127
7.1	Description des images par segments de contour.	132
7.2	Description par segments de contour	133
7.3	Description par paires de segments de contour	134
7.4	Description des images par un vocabulaire visuel.	134
7.5	Représentation spatiale pyramidale des images	135
7.6	Bases de données de véhicules pour la classification d'aspects	137
7.7	Principe d'extraction des segments de contour	138
7.8	Performances de classification pour différents niveaux de complexité	140
7.9	Masques binaires appliqués aux images pour biaiser le domaine cible	148
7.10	Validation du concept - Distribution moyenne des meilleures caractéristiques	149
7.11	Validation du concept - Résultats de classification par SVM	150
7.12	Validation du concept - Résultats de classification par GentleBoost	151
7.13	Cas réel - Distribution moyenne des meilleures caractéristiques	153
7.14	Cas réel - Résultats de classification sur les domaines source et cible	154
7.15	Cas réel - Écart de performance source-cible en fonction de l'AUC	155
A.1	Matériel utilisé pour la construction de la base de données.	163
A.2	Illustration du modèle de caméra utilisé pour la calibration.	164
A.3	Calibration de la caméra	165
A.4	Exemple d'acquisition	167

LISTE DES TABLES

1	Émergence de la vision active par ordinateur	3
2	Les différents niveaux de mise en œuvre de la vision active	4
4.1	Matrice de confusion du classifieur utilisé	67
5.1	Résumé des techniques d'apprentissage par renforcement	97
5.2	Comparaison du budget d'observations total requis par GPQL-2 et DPEGO .	104
7.1	Les différentes complexités de quantification des descripteurs	135
7.2	Performances de classification	139
7.3	Matrices de confusion pour le couple sac de mots-SVM	140
7.4	Validation du concept d'adaptation de domaine - Résumé des performances	152
7.5	Cas réel - Résumé des performances	152

INTRODUCTION

Le contexte de cette thèse est celui de la reconnaissance d'objets 3D à partir d'un agent autonome tel qu'un drone muni d'une caméra d'observation. La capacité de l'agent à explorer l'espace d'observation, en particulier à modifier ses conditions de prise de vue (CPDV), permet d'envisager la reconnaissance comme un processus d'inférence séquentiel. Une reconnaissance passive, où la (les) observation(s) sont subies par l'agent, peut s'avérer insuffisante lorsque la pose de l'objet observé génère des ambiguïtés ou lorsque la qualité de la modélisation ne permet pas de discriminer les classes. En guidant activement le processus d'acquisition de l'information à l'aide d'une stratégie, une qualité d'interprétation supérieure est susceptible d'être atteinte. L'élaboration de stratégies de vision active pour la reconnaissance d'objets est l'objectif de cette thèse.

1 RECONNAÎTRE LES OBJETS : UN BESOIN D'ORIGINE PHYSIOLOGIQUE

La vision est un moyen de perception naturel chez l'être humain et la plupart des animaux, et la reconnaissance visuelle est un processus physiologique fondamental. Notre activité, par exemple, repose en grande partie sur l'identification des objets et des autres personnes qui nous entourent. Cette faculté de reconnaissance est fondée sur la capacité à organiser l'information visuelle en catégories ou classes d'objets. Ces classes, généralement abstraites, peuvent être définies par des mots qui résument une fonction commune des instances qu'elle contient (une chaise, une voiture, un fruit . . .), et dont l'aspect commun de la fonction est issu d'un consensus [Brown, 1958; Rosch et al., 1976]. La classification visuelle d'un objet repose cependant sur des caractéristiques d'apparence communes avec les autres instances de la classe, et différentes des autres classes. Selon [Rosch et al., 1976], l'inférence est due à la présence d'un ensemble de caractéristiques ou "indices" visuels individuellement peu informatifs mais qui, combinés, forment des statistiques d'occurrences discriminantes.

L'inférence de la classe à partir de ces caractéristiques repose sur une représentation de la classe par un modèle ou prototype d'objet. [Logothetis et al., 1994] suggère une représentation mentale d'un objet par des collections d'images. D'autres chercheurs défendent l'idée d'une représentation plus abstraite qui nous permet d'inférer les classes à partir de poses variées des objets [Posner et Keele, 1968; Biederman, 1987]. Cela conduit [Logothetis et Sheinberg, 1996] à suggérer qu'une représentation mentale unique des objets n'existe pas, mais que celle-ci varie selon l'objectif de reconnaissance (i.e. le degré d'abstraction de la classe).

La compréhension et l'imitation par la machine du mécanisme cognitif d'inférence est l'un des défis majeur de l'intelligence artificielle qui a pris son essor dès le milieu du XX^{ème} siècle grâce au développement de l'informatique. Un exemple concret de ce désir est le récent projet SpiNNaker lancé par Steve Furber [Furber et Brown, 2009], qui vise à concevoir une architecture informatique semblable à celle du cerveau humain. Mais l'interprétation de données visuelles par un système artificiel ouvre également la voie à de nombreuses autres applications telles que la conduite automatique d'un véhicule [Kelly et Stentz, 1998], l'exploration de zones hostiles pour le renseignement par un robot tel que le Robonaut¹ mis au point par la NASA, la réalisations de tâches fastidieuses et répétitives comme la

1. <http://robonaut.jsc.nasa.gov/default.asp>

recherche d'images sur le web [Smeulders et al., 2000] ou encore le contrôle qualité en milieu industriel [Aguilera et al., 2007]. Alors que l'imitation du mécanisme d'inférence semble prévaloir, le mécanisme d'acquisition de l'information visuelle, en d'autres termes *quelle information acquérir* pour l'inférence, n'en est pas moins important dans le processus d'interprétation. Ce dernier mécanisme est central dans cette thèse.

2 VISION PASSIVE *VS.* ACTIVE

Le terme de *vision passive* est apparu dans les travaux fondateurs de D. Marr [Marr, 1983] qui a très tôt suggéré que ce comportement était caractéristique du système de vision humaine. La vision passive est caractérisée par l'absence de contrôle sur la manière d'acquieser l'information. Cette hypothèse s'appuie notamment sur le fait que la reconnaissance par l'être humain est fréquemment réalisée à partir d'une observation d'une très courte durée des objets.

L'hypothèse d'un traitement cognitif passif de l'information visuelle semble cependant trop simple. L'un des premiers à souligner cette insuffisance est [Gibson, 1968], à travers ses travaux sur l'attention visuelle chez l'être humain. L'attention visuelle est étroitement liée à la problématique de la vision active. Dans sa définition, elle consiste à sélectionner une information locale particulière de l'environnement au détriment d'autres informations. Dans leur livre, [Findlay et Gilchrist, 2003] remettent également en cause la validité du modèle passif face à notre capacité à traiter dans une unique représentation mentale une série d'observations partielles issues des mouvements saccadés de l'œil. Comment la représentation mentale supposée passive peut-elle être maintenue lorsqu'elle n'est formée qu'à partir d'une attention visuelle incomplète? Une intégration temporelle de l'information semble certaine dans notre processus de représentation.

Mais Gibson soutient également que la vision chez l'homme est non seulement gouvernée par une série d'actions, mais que la vision elle-même dirige l'action. En particulier, il soulève une problématique essentielle qui annonce la vision active : "Quelle est la cause d'un mouvement de l'œil dans une direction plutôt que dans une autre, et de prêter attention à un détail particulier plutôt qu'à un autre? La réponse ne peut venir que de structures intéressantes dans la scène, et d'éléments de structures intéressants, en particulier le mouvement, qui dirigent l'attention vers eux² [Gibson, 1968]". Cette focalisation de l'attention sur le mouvement est complétée par des séries d'expériences validant cette idée d'actions dirigée par la vision. L'une des plus connues est sans doute l'analyse du parcours visuel libre d'une scène statique, illustrée par la figure 1. Ce parcours semble être constant d'un individu à un autre et dépendre de la scène elle-même. Une autre expérience de [Harman et al., 1999] a montré que la manipulation d'objet et le changement de ses conditions d'observation jouait un rôle certain dans le processus de reconnaissance.

3 ORIGINES ET APPLICATIONS DE LA VISION ACTIVE PAR ORDINATEUR

La vision active par ordinateur a très tôt suscité un intérêt. Les premiers travaux sont apparus dès le début des années 1980. Une chronologie intéressante de son développement, toutes applications confondues, est suggérée par J. L. Crowley. Elle est résumée par la table 1.

Les applications de la vision active sont nombreuses. Le terme *actif* revêt lui-même plusieurs significations. La table 2 suggère de les distinguer selon la nature des actions et de l'application. Une première catégorie rassemble les capteurs actifs, où *actif* renvoie à la technologie d'acquisition des données. Une deuxième catégorie, qui est celle que nous

2. "What causes the eyes to move in one direction rather than another, and to stop at one part of the array instead of another? The answer can only be that interesting structures in the [visual] array, and interesting bits of structure, particularly motions, draw the foveas towards them".




FIGURE 1 – Exemple de parcours visuels libres d'une image.

retiendrons, a été suggérée par [Bajcsy, 1988]. Le terme actif désigne cette fois la stratégie d'acquisition. Un capteur à technologie passive (i.e., qui ne fait que recevoir l'information, sans émettre de signaux) peut être utilisé activement (par exemple par un déplacement physique dans la scène).

1980	L'un des premiers travaux sur l'asservissement visuel [Sanderson et Weiss, 1980] (la notion de vision active n'est alors pas encore explicite)
1982	Le terme "actif" apparaît pour la première fois, utilisé par R. Bajcsy lors d'un Workshop OTAN.
1987	Première revue consacrée à la vision active [Aloimonos et al., 1987]
1988	Travaux sur la perception active, présentés par R. Bajcsy [Bajcsy, 1988]
1989	Une session entière est consacrée à la vision active lors d'une conférence ICCV (<i>International Conference on Computer Vision.</i>).
1991	Article de référence sur l'étude des problématiques et de l'apport d'un contrôle actif de l'attention visuelle [Ballard, 1991].

TABLE 1 – Émergence de la vision active par ordinateur (http://home-pages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/ECVNET/CROWLEY1/node2.html).

Les actions considérées par un système actif peuvent également être de nature non intrusive (i.e. le capteur ne se déplace pas physiquement dans la scène), ou intrusive. Plusieurs revues détaillées des applications en vision active, notamment à l'aide de capteurs passifs utilisés activement, sont disponibles ([Tarabanis et al., 1995; Dutta et al., 2004; Chen et al., 2008]). Un système actif et invasif muni de capteurs passifs est considéré dans cette thèse.

4 CARACTÉRISTIQUES D'UN SYSTÈME DE VISION ACTIVE

La réussite de la mise en œuvre d'un système de vision active s'accompagne, quelle que soit l'application, d'une série de questions qu'il convient de définir précisément et auxquelles il convient également de répondre.

1. Quelle information est acquise et comment celle-ci est-elle intégrée dans ce processus de décision séquentiel? Cette question fait référence à la manière d'extraire l'information visuelle des images, de la combiner à l'information déjà acquise dans un *processus de décision séquentiel*.
2. Comment la décision d'effectuer une nouvelle action est-elle prise? Cela conduit à la notion de *politique de planification* des actions selon un *critère d'optimalité*. La planifica-

Niveau	Nature de l'action	Objectif poursuivi	Exemples
Capteur	Réglage des paramètres internes	Qualité de la mesure	Mise au point (focus), ajustement de l'ouverture.
Vision "bas niveau"	Non intrusive; signaux sonores, lumineux ...	Extraction d'informations non perceptibles passivement	Capteur Time-Of-Flight (radar, sonar actif, lidar); Scanner 3D; Kinect™
	Intrusive; déplacement dans la scène, toucher	Extraction d'informations 3D	Reconstruction 3D [Marchand et Chaumette, 1999; Kamada et Kawai, 1988], cartographie [Kelly et Stentz, 1998; Sim, 2000], asservissement visuel [Malis, 2002].
Vision "haut niveau"	Non intrusive	Interprétation	attention visuelle [Remagnino et al., 1995; Zhou et al., 2003].
	Intrusive	Interprétation	reconnaissance 3D [Arbel, 2000; Herbin, 1997; Borotschnig et al., 2000; Denzler et Brown, 2002], recherche d'objets [Ye et al., 1999].

TABLE 2 – Les différents niveaux de mise en œuvre de la vision active et exemples d'applications.

tion doit également tenir compte de l'état actuel de connaissance de la scène et rester efficace malgré des changements inattendus de celle-ci. Cette notion d'*autonomie*, sous-jacente à la vision active, est centrale.

3. Comment la décision de terminer le processus est-elle prise ? La vision active nécessite la définition d'un *objectif* à atteindre.

Ces caractéristiques sont regroupées au sein d'une boucle fermée de traitements dans laquelle l'information perçue guide les actions du système, principe fondamental de la vision active. Cette boucle est illustrée par la figure 2.

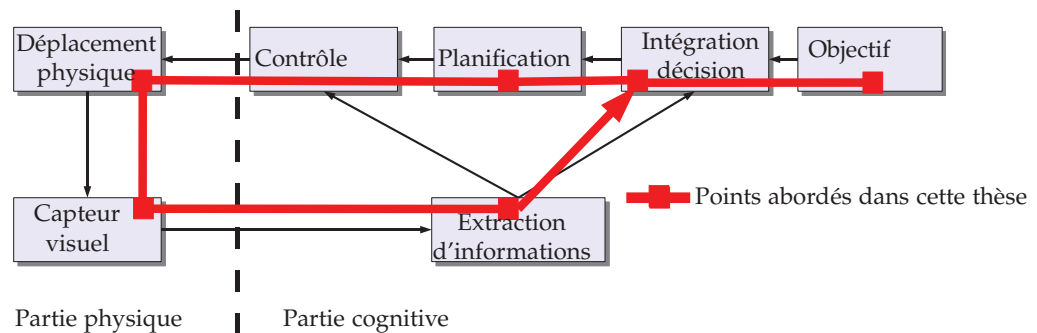


FIGURE 2 – Boucle générale d'action et de traitement de l'information perçue en vision active. La boucle rouge correspond aux différents points abordés dans cette thèse.

5 VISION ACTIVE POUR LA RECONNAISSANCE

Contexte

La plupart des algorithmes de reconnaissance actuels sont passifs. Dans ce cas l'information visuelle de la scène est subie par le système. La raison du développement considérable de cette catégorie d'algorithmes semble être plutôt liée à la nature des applications. La banalisation des données multimédia a encouragé les applications de reconnaissance reposant sur des données existantes (i.e. subies par l'algorithme) comme des séquences

vidéo (par exemple l'analyse de mouvement [Gavrila, 1999]), ou des données passives *et* statiques comme des images (voir par exemple [Ponce, 2006]), réduisant alors le problème de reconnaissance 3D à un problème de reconnaissance 2D.

Cependant, la reconnaissance d'objets 3D à partir d'une représentation 2D (sur la rétine de l'œil pour un humain ou sur le capteur d'une caméra pour un système artificiel) est une tâche difficile, du fait de la perte d'information inhérente à la projection. Bien que des techniques ont été suggérées pour tenter de reconstruire cette information manquante [R. A. Jarvis, 1983], pour l'humain comme pour la machine, l'approche passive pour la reconnaissance peut se révéler insuffisante dans une grande variété de cas. Par exemple, des caractéristiques visuelles peuvent être occultées par l'objet lui-même, rendant l'inférence incertaine voire impossible. Une autre difficulté surgit lorsque plusieurs objets présentent des apparences similaires sous le point de vue considéré. Cela peut par exemple être à cause d'une résolution insuffisante ou de similarités intrinsèques. Enfin, lorsque la discrimination de deux objets repose sur un niveau d'analyse et de détails fins, un tel niveau de complexité de modélisation mathématique peut s'avérer délicat à atteindre. De tels objets pourraient être reconnus en modifiant les modalités d'acquisition et en réalisant l'inférence à partir d'une séquence d'observations. De cette manière, la multiplication des informations visuelles est susceptible de conduire à une inférence finale robuste sans pour autant complexifier la modélisation. Mais le choix non contrôlé des modalités d'acquisition n'est pas suffisant car un objet peut dans ce cas toujours avoir une apparence semblable à un autre. Un comportement actif de l'observateur avec des actions intentionnelles est nécessaire.

La vision active pour la reconnaissance, que nous appellerons également reconnaissance active, est l'objet de cette thèse. En particulier, la figure 2 précise les éléments de la boucle d'action qui sont considérés dans nos travaux. La reconnaissance active offre plusieurs avantages par rapport à l'approche passive. Dans de nombreux cas, en recherchant les observations d'un objet pour lesquelles il n'y a pas d'ambiguïté avec un autre, une reconnaissance non ambiguë est possible. Ce phénomène est illustré par la figure 3. D'autre part, lorsqu'une modélisation fine des objets est requise pour les discriminer, la vision active préfère reporter une partie des efforts sur la recherche d'autres CPDV, offrant ainsi une ambiguïté visuelle moindre pour une complexité de modélisation inférieure. Un autre avantage de la planification impliquée dans le processus actif est, dans certains cas, de réduire la complexité de la tâche à résoudre par rapport à une recherche exhaustive. [Tsotsos, 1992] a montré en particulier cet avantage dans le cas d'une recherche visuelle non bornée (i.e. sans a priori sur les objets d'intérêt commun entre une image de référence et une image test).

Revue de la littérature et motivations

Comme l'illustre la figure 2, la majorité des travaux en reconnaissance active est à la croisée des domaines de l'apprentissage statistique, de la fusion de données, de la vision par ordinateur et de la commande. Du fait de cette transversalité, il nous a semblé approprié de positionner la littérature existante relativement aux domaines abordés dans cette thèse. Pour cela, une revue des travaux connexes à chaque chapitre est présentée au début de ceux-ci. Néanmoins, un ensemble de travaux remarquables qui ont inspiré la plupart des développements de cette thèse sont ici énumérés.

Principaux travaux précédents

- [Herbin, 1997] propose, dans sa thèse, une possibilité de formalisation mathématique de la vision active pour la reconnaissance. En particulier, une représentation markovienne d'états sensibles (qui sont assimilés aux aspects de l'objet) permet de caractériser des transitions discriminantes qui suggèrent la sélection des actions à effectuer

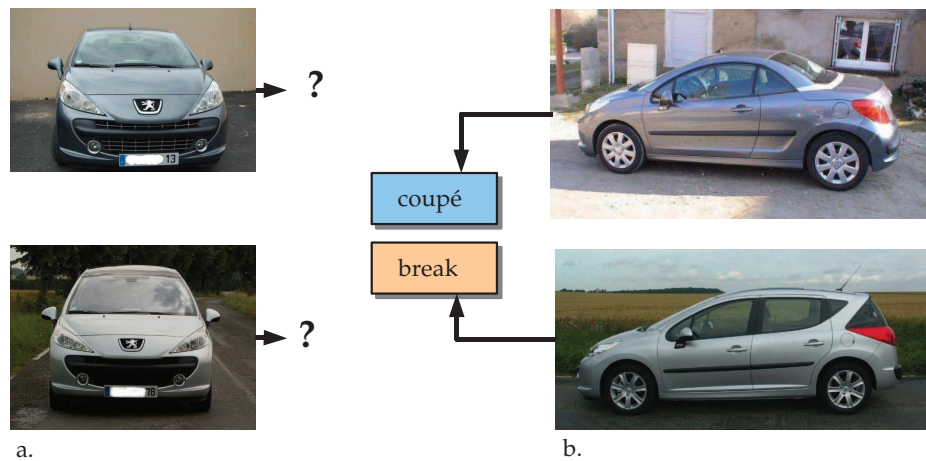


FIGURE 3 – Illustration par un exemple du besoin de la vision active pour la reconnaissance ; a. véhicules vus de face (apparence similaire) ; b. les mêmes véhicules vus de profil. La discrimination des classes (break vs. coupé) n'est possible qu'en modifiant les CPDV.

dans l'espace des CPDV pour la reconnaissance. Les notions de filtrage conservatif, qui permet de limiter les erreurs de discrimination, et de filtrage sélectif, qui permet de limiter le rejet erroné des classes, sont des notions (abordées sous des formes différentes) à la base des chapitres 4 et 6 de la présente thèse.

- [Arbel, 2000] met en œuvre dans sa thèse une reconnaissance active d'objets en environnement contrôlé (les objets sont segmentés du fond). Bien que la reconnaissance soit basée sur une signature du mouvement des objets (flot optique), qui n'est pas considérée dans cette thèse, l'auteur introduit la notion de carte d'entropie des objets. Cette mesure d'ambiguïté de la reconnaissance permet de guider explicitement le choix des prochaines CPDV. Cet outil de planification, qui fait partie de l'état de l'art, est utilisé ici dans les comparaisons, en particulier au chapitre 4.
- [Borotschnig et al., 2000] suggèrent une reconnaissance active basée sur une modélisation d'apparence dans un espace de dimension réduite. Ces modèles de faible complexité permettent une inférence à la fois de la pose et de la classe de l'objet observé. Bien que leur mise en œuvre soit effectuée en environnement contrôlé (comme pour [Arbel, 2000], les objets sont segmentés du fond de l'image), ils ont en partie guidé le choix de la modélisation adoptée dans cette thèse. La planification repose également sur une mesure d'entropie.
- [Denzler et Brown, 2000] proposent un formalisme mathématique pour l'intégration séquentielle des observations dans le processus de reconnaissance active ainsi que pour la sélection (par entropie) de la prochaine observation.
- Enfin, [Paletta et Pinz, 2000] ont été parmi les premiers à développer une procédure d'apprentissage par renforcement d'une politique de planification des CPDV. Ces travaux constituent le point de départ du chapitre 5.

Limitations des travaux existants

L'ensemble des travaux en reconnaissance active repose cependant sur des hypothèses simplificatrices communes. La première d'entre elles est la modélisation fondée sur une étape de segmentation des objets (c'est le cas notamment de [Paletta et Pinz, 2000; Borotschnig et al., 2000; Arbel, 2000]). Ce pré-traitement offre l'avantage de pouvoir modéliser facilement et efficacement les objets et d'utiliser ces modèles pour une estimation robuste de la pose simultanément à celle de la classe. Cependant, la segmentation des objets en environnement non contrôlé est souvent délicate et génératrice d'erreurs. Ce pré-traitement des données est évité dans cette thèse, ce qui constitue un pas important vers une mise en œuvre plus réaliste de la reconnaissance active.

Une deuxième caractéristique commune aux travaux précédents est une disponibilité illimitée des données d'apprentissage (du classifieur comme des stratégies de planification). Or, l'acquisition d'une observation peut être coûteuse en temps ou en énergie. Dans cette thèse, l'ambition d'une mise en œuvre réaliste de la reconnaissance active est également liée à une quantité limitée de données d'apprentissage.

Enfin, un troisième aspect non considéré jusqu'à présent est celui d'une interprétation progressive de l'information. Alors que la reconnaissance est réalisée à partir d'une séquence d'observations, la possibilité d'une interprétation provisoire après chaque observation n'est pas mise à profit pour l'utilisateur. Celle-ci est cependant susceptible d'apporter des renseignements utiles, en particulier dans des contextes de prise de décision où la rapidité d'interprétation est importante.

Ces considérations ont conduit aux contributions présentées ci-après.

Bases de données et cadre applicatif

L'application à la reconnaissance de véhicules est considérée tout au long de cette thèse. Une telle application est très représentative du fait de similarités intrinsèques importantes entre les objets et de différences visuelles parfois ténues. Pour cela, plusieurs bases de données ont été construites spécifiquement pour la mise en œuvre de la reconnaissance active.

- La première d'entre elles est décrite au chapitre 3. Elle rassemble des collections d'images de douze véhicules différents. Les images sont annotées à la fois par leur classe et par leur CPDV afin d'être utilisées pour l'apprentissage du classifieur et des politiques de planification.
- Deux autres bases de données sont formées par des collections d'image regroupant une variété importante de véhicules. Chaque image est cette fois annotée par l'aspect sous lequel est vu l'objet. Ces bases sont décrites au chapitre 5. Elles sont en particulier utilisées pour l'apprentissage d'un classifieur d'aspect des véhicules.

6 CONTRIBUTIONS

Les contributions de cette thèse visent à permettre une mise en œuvre réaliste de la reconnaissance active d'objets 3D par un agent visuel autonome. Le cadre de l'apprentissage statistique, qui offre de puissants outils d'inférence à partir de données réelles et parfois imparfaites, est mis à profit pour tenter de pallier plusieurs difficultés importantes soulevées dans les travaux précédents, ainsi que des hypothèses parfois trop simplificatrices.

Les contributions concernent tout d'abord la conception de nouvelles procédures d'apprentissage d'une politique de planification des CPDV.

1. **La contrainte d'une modélisation mathématique imparfaite des objets est considérée.** Ces imperfections, dues notamment aux bruits de mesures et à un nombre fini de données d'apprentissage, peuvent conduire, pour certaines CPDV, à une erreur de classification parfois plus importante que celle d'une classification aléatoire. La mesure classique de l'ambiguïté entre les classes utilisée en reconnaissance active, l'entropie, est alors inefficace. Un nouveau critère appelé *critère adaptatif*, est pour cela proposé (chapitre 4). En utilisant directement le résultat du classifieur dans une procédure d'apprentissage, les imperfections des modèles sont prises en compte par la politique de planification des CPDV. Ce critère permet également une planification adaptée à l'état de connaissance courant sur l'objet, caractéristique essentielle de la vision active. Ce nouveau critère de planification est appliqué à la reconnaissance active de véhicules et comparé à l'entropie.
2. **L'apprentissage de la politique de planification des CPDV est considéré avec un budget d'observations restreint.** Cette limitation du nombre de données d'apprentissage est justifiée par le coût et la difficulté d'acquérir celles-ci en situation réelle.

Cette contrainte n'a, à notre connaissance, pas été considérée dans les travaux précédents. Ce coût peut être une dépense en énergie ou en temps associée à chaque observation acquise. La réduction de celui-ci passe donc par la restriction du budget d'observations. Pour conserver de bonnes performances de la politique de planification sous cette contrainte, un apprentissage par renforcement couplé aux processus gaussiens est proposé (chapitre 5). En particulier, les méthodes Q-learning et programmation dynamique sont utilisées. Ce couplage permet un apprentissage actif de la politique de planification offrant, pendant l'apprentissage, la capacité de sélectionner les observations les plus utiles et ainsi de réduire le budget nécessaire. Les techniques d'apprentissage développées sont mises en œuvre et évaluées sur l'application à la reconnaissance active de véhicules.

Un deuxième axe de recherche consiste en l'application de techniques d'apprentissage supervisé pour une exploitation plus efficace des observations au cours de la reconnaissance active. Dans ce cadre, deux autres contributions sont apportées.

- 3 **Une meilleure exploitation de l'aspect séquentiel de la reconnaissance active est proposée.** Pour cela, une hiérarchie d'interprétation est construite de manière autonome (chapitre 6). Elle permet, par un filtrage progressif des classes après chaque observation, d'envisager un compromis entre précision et confiance. Dans ce but, le cadre de discernement (i.e. le sous-ensemble de classes potentielles) est rendu dynamique pour permettre une interprétation multi-échelles. Au cours de la reconnaissance, si l'objet n'est pas classé avec une confiance suffisante, des classes peuvent néanmoins être écartées progressivement et avec une confiance acceptable. L'approche proposée permet un parcours autonome dans le graphe de hiérarchie. La réduction progressive du cadre de discernement conduit certaines CPDV jusqu'alors peu informatives à devenir bénéfiques pour la reconnaissance. Dans ce but, nous avons également construit une hiérarchie de planification, appelée planification *adaptive multi-échelles* (AME), capable de capturer cette émergence au cours de la reconnaissance. Ce couplage entre classification hiérarchique et planification AME permet d'envisager un compromis entre confiance et précision de l'interprétation en reconnaissance active.
- 4 **Une estimation robuste de la pose des objets, indépendante du processus de reconnaissance, est élaborée.** La connaissance de la pose de l'objet est nécessaire à chaque observation pour le placement correct de l'agent aux CPDV planifiées. Son estimation est généralement admise dans les travaux précédents ou estimée conjointement avec la classe lorsque la qualité des modèles le permet. Cependant, lorsque les modèles sont imparfaits, cette dernière méthode est peu robuste. Dans le cas de véhicules, un classifieur d'aspects indépendant des classes et compatible avec les contraintes précédentes est conçu. La bonne généralisation du classifieur est primordiale pour son utilisation sur des véhicules n'appartenant pas à la base d'apprentissage. Dans ce but, une nouvelle procédure de sélection optimale des paramètres du descripteur pour la classification simultanée des deux bases est également définie. Elle permet une adaptation de domaine du classifieur lorsque la base cible présente un biais inconnu, sans nécessité de réitérer l'effort d'annotation effectué sur la base source.

7 ORGANISATION GÉNÉRALE DU DOCUMENT

Cette thèse est divisée en trois parties et comporte sept chapitres au total.

La première partie présente un formalisme et un état de l'art nécessaires à la mise en œuvre de la reconnaissance active par un système visuel artificiel.

Avant de considérer l'aspect actif, le chapitre 1 pose la problématique d'une reconnaissance supervisée par ordinateur, en particulier lorsque l'information est une image.

Comment faire comprendre les images à la machine? Quelle information extraire, et comment un algorithme peut apprendre à classifier automatiquement? Différentes modélisations, en particulier les approches générative et discriminative sont décrites, ainsi que différentes stratégies de description des images pour la reconnaissance.

Le chapitre 2 pose le formalisme spécifique à la reconnaissance active. La boucle globale de reconnaissance est considérée, selon un point de vue probabiliste. En particulier, un schéma d'intégration bayésienne séquentielle est défini et la stratégie de sélection des prochaines CPDV y apparaît explicitement. Une revue de plusieurs stratégies, ainsi que leurs avantages et leurs inconvénients, est également proposée.

Dans le chapitre 3, le formalisme défini précédemment est complété par le choix d'une modélisation des objets. Le cadre expérimental pour une implémentation effective de la boucle de reconnaissance active est ensuite présenté. Une base de données de véhicules, qui sera considérée tout au long de cette thèse, est introduite.

La deuxième partie de cette thèse est consacrée à la définition de stratégies de planification des CPDV pour une mise en œuvre réaliste.

Dans le chapitre 4, l'aspect réaliste est focalisé sur une modélisation imparfaite des objets. Une remise en question de l'efficacité de l'entropie est justifiée, et le critère adaptatif est défini. Ce critère est évalué sur les bases de données décrites aux chapitre 3.

Le chapitre 5 vient compléter le chapitre 4 en s'attachant cette fois à réduire le coût d'apprentissage de la politique de planification des CPDV. La combinaison de l'apprentissage par renforcement et d'un apprentissage actif par processus gaussiens est décrite et appliquée à la reconnaissance de véhicules. Une comparaison avec les approches existantes en apprentissage par renforcement est également réalisée.

La troisième partie de cette thèse rassemble deux chapitres qui envisagent une autonomie totale de l'agent visuel pour la reconnaissance active, au delà de l'apprentissage de la politique de planification.

Le chapitre 6 présente une stratégie de classification hiérarchique exploitant l'acquisition séquentielle de l'information. Un graphe hiérarchique est défini pour la reconnaissance, et une organisation autonome de l'interprétation dans ce graphe est décrite. La nouvelle stratégie de planification adaptative associée, fondée sur les critères d'utilité établis dans les chapitres précédents, est ensuite abordée. Une étude expérimentale du comportement de cette approche est réalisée.

Le chapitre 7 présente la technique d'estimation de la pose des objets par classification d'aspect. Dans la première partie du chapitre, plusieurs descripteurs et classifieurs sont mis en œuvre et comparés, et une étude empirique de la complexité de description est réalisée. Dans la deuxième partie, la nouvelle procédure d'adaptation de domaine est décrite pour améliorer la généralisation des classifieurs. Deux bases d'aspects de véhicules sont considérées (source et cible). Le principe de sélection des paramètres du descripteur pour l'adaptation, ainsi que le compromis entre la performance de classification sur la base source et la base cible sont évalués.

PARTIE 1
ÉTAT DE L'ART ET OUTILS
MATHÉMATIQUES

CLASSIFICATION SUPERVISÉE POUR LA RECONNAISSANCE

1

LA reconnaissance active par ordinateur fait intervenir une chaîne de traitement des observations acquises. Cette chaîne consiste à exploiter les données numériques, ici les pixels d'une image, pour en extraire une information de haut niveau, la classe de l'objet. Indépendamment de l'aspect "actif", c'est l'aspect "reconnaissance" des objets sur les images qui est au centre de ce chapitre. Cette reconnaissance est réalisée classiquement en deux étapes, schéma adopté ici : une étape de description et une étape de classification. L'objectif de ce chapitre est d'apporter, par une étude bibliographique, une vision concise des différentes techniques d'apprentissage supervisée pour la reconnaissance automatique (section 1.2) et de description des images (section 1.3). Les aspects historiques et l'évolution des différents paradigmes sont également évoqués, dans le souci d'une compréhension de la démarche entreprise ces dernières décennies pour *faire comprendre une image à la machine*.

PLAN DU CHAPITRE

Ce chapitre est organisé de la manière suivante : après un rappel du contexte historique de la naissance de l'apprentissage statistique à la section 1.1, l'apprentissage supervisé est abordé à la section 1.2. La théorie de Vapnik est au centre de la démarche proposée. Les différentes stratégies d'apprentissage existantes dans la littérature sont évoquées à la section 1.2.3. La description des images, souvent nécessaire à la classification, est ensuite abordée à la section 1.3, à travers une bibliographie des modélisations 2D et 3D. Enfin, la réduction de la dimension des descripteurs et la sélection de caractéristiques, souvent concomitantes à la description, font également l'objet de nombreuses approches. Une revue concise de ces approches est réalisée à la section 1.3.4.

1.1 INTRODUCTION

La résolution d'un problème de classification supervisée a donné naissance à de nombreuses techniques d'apprentissage statistique. L'objectif de l'apprentissage statistique est de fournir un cadre formel pour inférer, c'est-à-dire réaliser des prédictions, prendre des décisions ou extraire de l'information à partir d'un ensemble de données mesurées, et ce de manière autonome. Le problème revient à rendre compte au mieux, c'est à dire avec une erreur minimale, du processus inconnu ayant généré les données uniquement à partir de la connaissance de ces dernières. L'étude est menée dans un cadre où le lien entre le processus générateur et les données est de nature statistique.

Le besoin de prévoir et les premiers outils de prévision associées sont très anciens. Les recensements de population, qui visent à estimer une valeur typique à partir d'un échantillon d'individus mettent en œuvre dès le XVIII^{ème} siècle des techniques sophistiquées qui marquent le début de la statistique inférentielle. L'âge d'or de l'inférence statistique a été marqué au début du XX^{ème} siècle notamment par les travaux de Jerzy Neyman, Ronald Fisher, ou encore Karl Pearson.

L'apprentissage statistique a pris son élan tout d'abord dans le domaine de l'intelligence artificielle (sous le nom d'apprentissage automatique, ou encore apprentissage artificiel), dans les années 1950, sous l'impulsion de l'article fondateur de Turing ([Turing, 1950]). Dans le but de rendre une machine "intelligente" et d'approcher le niveau de l'être humain, la stratégie proposée par Turing pour surmonter la difficulté de programmation était d'écrire un programme permettant à la machine d'apprendre à partir de stimuli extérieurs, à la manière d'un être humain. Les premiers succès de cette approche, bien que modérés, s'avèrent immédiats. Parmi eux, on peut citer le programme d'apprentissage autonome pour jouer au dames d'Arthur Samuel qui fait figure de pionnier. L'essor de cette idée s'est prolongé par la mise en œuvre des réseaux de neurones à la fin des années 1950 [Rosenblatt, 1958], directement inspirés du fonctionnement biologique.

Le développement de l'intelligence artificielle, qui à ses débuts prônait la simplicité des programmes, n'a pas été lié à celui de la statistique, attachée à une modélisation mathématique parfois complexe des problèmes. Cette divergence, soulignée par [Vapnik, 2000], a été cependant progressivement réduite par ses travaux, dans lesquels l'apprentissage statistique repose sur des bases communes à ces deux disciplines. Une connexion entre les méthodes neuronales et la statistique a été établie par [Thiria et al., 1997]. Dans [Friedman, 1998], l'auteur partage également cette vision commune, et l'apprentissage statistique peut désormais être considéré comme résultant des statistiques inférentielles et de l'intelligence artificielle.

Les applications de l'apprentissage statistique sont aujourd'hui très nombreuses et permettent d'affranchir l'être humain de tâches répétitives et fastidieuses. Il peut s'agir par exemple de reconnaître automatiquement des caractères manuscrits et de trier le courrier à partir de la lecture du code postal par la machine. La variabilité des écritures est apprise par le système de reconnaissance. Un autre exemple concerne la détection automatique

de courrier indésirable (spam) dans les boîtes à lettres électroniques. À partir de l'annotation manuelle d'une petite quantité de ces messages, le client de messagerie apprend à identifier automatiquement les futurs messages et à écarter les indésirables (se référer à [Hastie et al., 2009] pour plus de détails sur ces exemples). La reconnaissance automatique d'objets, qui est étudiée dans cette thèse, constitue un autre grand domaine d'application de l'apprentissage statistique.

Le principe de l'apprentissage supervisé pour la classification de données est illustré par la figure 1.1. Le découplage entre la représentation des données brutes en données utilisables par les algorithmes de classification, qui est souvent le cas en reconnaissance d'objet, est suggéré. Les techniques de description sont reportées à la section 1.3. L'étape d'apprentissage du classifieur à partir des données est maintenant abordée.

1.2 APPRENTISSAGE SUPERVISÉ

Cette section est consacrée à la définition d'un cadre formel pour l'apprentissage statistique. Le cas de la classification est considéré, l'inférence est alors de nature qualitative (ou catégorique). Le cas particulier de la classification supervisée, qui sera mise en œuvre dans les chapitres suivants, est présenté. Son principe est illustré par la figure 1.1. Dans cette section, l'étape de représentation des données est supposée réalisée. Le cadre adopté est celui de la théorie de l'apprentissage selon Vladimir N. Vapnik [Vapnik, 2000]. D'autres ouvrages présentent l'apprentissage statistique de manière détaillée [Bishop, 2006; Hastie et al., 2009] ou plus concise [Jain et al., 2000; Bousquet et al., 2004].

1.2.1 Hypothèses

La mise en œuvre de l'apprentissage supervisé s'accompagne souvent d'hypothèses sur les données. Les espaces probabilisés et les variables aléatoires sont au cœur des notions introduites. Le succès de l'apprentissage repose tout d'abord sur l'hypothèse de l'existence d'un processus (inconnu) stationnaire à l'origine des données. Ces données sont supposées mutuellement indépendantes, c'est-à-dire qu'elles apportent toutes autant d'information. La connaissance du processus générateur (qui est ici représenté par une distribution de probabilité) permettrait d'expliquer l'ensemble des données futures. Cette connaissance est l'objectif ultime de l'inférence. Cependant, atteindre cet objectif ambitieux n'est généralement pas nécessaire. Le classifieur recherché dans la majorité des applications doit avant tout permettre de prédire la classe avec une erreur minimale, sans pour autant prédire le comportement des données au sein des classes.

Le problème de l'inférence à partir d'un ensemble fini de données d'apprentissage fait partie de la catégorie des problèmes inverses : alors que le processus générateur est unique, son estimation à partir d'un jeu fini de données peut conduire à une infinité de solutions possibles. Pour cela, l'optimalité de la solution est tout d'abord guidée par la recherche de consistance : le comportement du classifieur doit tendre vers la "vraie" solution lorsque la quantité de données d'apprentissage augmente.

Cependant, la consistance seule ne suffit pas. Un classifieur non consistant peut se révéler plus performant lorsque le nombre de données d'apprentissage est faible. Cela conduit à évaluer la capacité de généralisation du classifieur. Une généralisation efficace s'accompagne, comme dans tout problème inverse, d'une connaissance a priori sur la solution. Cette connaissance a priori permet de restreindre l'ensemble des solutions *possibles* à un ensemble de solutions *plausibles* pour le problème considéré.

Les définitions formelles des notions abordées jusqu'à présent sont présentées dans la section suivante dans le cas de la classification binaire.




FIGURE 1.1 – Principe de la classification par apprentissage supervisé. Le découplage entre la représentation des données et la classification, généralement rencontré en classification d'image, est représenté.

1.2.2 Classification binaire : rappels théoriques

Une donnée est définie par la variable aléatoire x appartenant à un espace de représentation (ou espace d'entrée) \mathcal{X} . Cette donnée est associée à une classe définie par la variable aléatoire $\omega \in \Omega$. Ω est appelé l'espace de sortie ou espace de classes. Dans le cas d'une classification binaire, $\Omega = \{-1; 1\}$. Le couple donnée-classe (x, ω) est distribué sur $\mathcal{X} \times \Omega$ selon la distribution de probabilité

$$P(x, \omega) = P(x)P(\omega | x) \quad (1.1)$$

le terme $P(x)$ représente la probabilité a priori de mesurer x , tandis que $P(\omega | x)$ est la probabilité a posteriori d'appartenance de la donnée x à la classe ω . Cette dernière probabilité est inconnue.

L'objectif recherché consiste à prédire la classe ω à partir de x par le biais d'une fonction $f : \mathcal{X} \mapsto \Omega$ appelée classifieur. Le classifieur optimal est celui qui imite fidèlement le classifieur issu de $P(\omega | x)$. Il est appelé classifieur de Bayes et est défini par :

$$f_{\text{Bayes}}(x) = \underset{\omega}{\operatorname{argmax}} P(\omega | x) \quad (1.2)$$

Le classifieur $f_{\text{Bayes}}(\cdot)$ étant inconnu, un classifieur s'en approchant le plus est recherché à partir d'un ensemble de données d'apprentissage. Il est noté $\hat{f}(\cdot)$. Le critère d'optimalité est basée sur la minimisation de l'erreur de prédiction. Cela nécessite la définition d'une fonction de perte $\mathcal{L}(\omega, \hat{f}(x))$. La perte espérée par $\hat{f}(\cdot)$ sous la distribution des données conduit à la définition du risque :

$$\begin{aligned} \mathcal{R}(\hat{f}(\cdot)) &= \mathbb{E}(\mathcal{L}(\omega, \hat{f}(x))) \\ &= \int_{\mathcal{X} \times \Omega} \mathcal{L}(\omega, \hat{f}(x)) dP(x, \omega) \end{aligned} \quad (1.3)$$

L'erreur de prédiction par $f_{\text{Bayes}}(\cdot)$ est l'erreur minimale théorique que l'on peut espérer obtenir. Elle est appelée risque de Bayes et est définie par $\mathcal{R}(f_{\text{Bayes}}(\cdot))$. Le problème d'apprentissage supervisé se définit de la manière suivante : étant donné un ensemble de données annotées (ou données d'apprentissage) $\mathcal{A}_N = \{(x_1, \omega_1), \dots, (x_N, \omega_N)\}$, déterminer le classifieur $\hat{f}(\cdot)$ qui minimise (1.3). L'annotation, encore appelée avis d'expert, est généralement réalisée manuellement et est censée reproduire le résultat de $f_{\text{Bayes}}(\cdot)$ pour le jeu \mathcal{A}_N .

Compromis biais-variance

Le classifieur de Bayes est inconnu, et sa complexité peut être importante. Or, si une complexité importante est autorisée pour $\hat{f}(\cdot)$, ce modèle de classification est susceptible

de conduire à une frontière très sinueuse dans l'espace de représentation. Les données d'apprentissage \mathcal{A}_N seront bien classées, mais du fait de ce comportement sinueux, la classification d'un nouveau point sera probablement fautive. Un tel phénomène est qualifié de sur-apprentissage. L'apprentissage de $\hat{f}(\cdot)$ à partir d'un ensemble fini de données ne peut être effectuée sans restreindre l'espace des fonctions possibles à une famille \mathcal{F} de complexité limitée afin de se prémunir du sur-apprentissage. La complexité est par exemple liée au nombre de paramètres (ou degrés de liberté) dans le cas d'un espace de fonctions paramétriques. Vapnik utilise la notion de dimension VC¹ pour définir formellement la complexité de \mathcal{F} [Vapnik, 2000], dont la définition est rappelée ci-après.

Définition 1.1 *Dimension VC*

Étant donnée une famille \mathcal{F} de classifieurs, on dit qu'un jeu de points $\{x_1, \dots, x_N\}$ est pulvérisé si pour tout étiquetage possible de la forme $\{(x_1, \omega_1), \dots, (x_N, \omega_N)\}$, il existe un classifieur $f \in \mathcal{F}$ conduisant à une erreur de classification nulle (il y a 2^N étiquetages différents à considérer pour le jeu de points lorsque $\omega \in \{-1; 1\}$).

La dimension VC de \mathcal{F} est égale au nombre maximal de points qui peuvent être pulvérisés (notons que la position des points dans l'espace de représentation peut être choisie lors du calcul de la dimension VC).

Le choix de la famille \mathcal{F} (et de sa complexité) conditionne l'optimalité du descripteur. Étant donnée la famille \mathcal{F} , le classifieur optimal, noté $\hat{f}_{\text{opt}}(\cdot)$ est défini par

$$\hat{f}_{\text{opt}}(\cdot) = \underset{\hat{f} \in \mathcal{F}}{\operatorname{argmin}} \mathcal{R}(\hat{f}(\cdot)) \quad (1.4)$$

Lorsque $f_{\text{Bayes}}(\cdot) \in \mathcal{F}$, cette optimalité peut être atteinte. Ce cas de figure est cependant rare, et il existe souvent un biais structurel entre $\hat{f}_{\text{opt}}(\cdot)$ et $f_{\text{Bayes}}(\cdot)$. Ce biais est défini par :

$$\text{Biais}(\hat{f}(\cdot)) = \mathcal{R}(\hat{f}_{\text{opt}}(\cdot)) - \mathcal{R}(f_{\text{Bayes}}(\cdot)) \geq 0 \quad (1.5)$$

Le biais peut être réduit en augmentant la complexité de \mathcal{F} . Mais la contrepartie est une possible perte de stabilité du classifieur : une petite perturbation des données d'apprentissage est susceptible de modifier sensiblement le comportement du classifieur, conduisant à une variance importante du risque au sein de \mathcal{F} . Notons que cette notion de variance diffère ici de la définition habituelle. Elle traduit le fait que si l'ensemble d'apprentissage avait été différent, un autre classifieur aurait été estimé. Cette variance du classifieur est définie par :

$$\text{Variance}(\hat{f}(\cdot)) = \mathcal{R}(\hat{f}(\cdot)) - \mathcal{R}(\hat{f}_{\text{opt}}(\cdot)) \geq 0 \quad (1.6)$$

Le risque d'un classifieur peut donc être décomposé de la manière suivante :

$$\mathcal{R}(\hat{f}(\cdot)) = \mathcal{R}(f_{\text{Bayes}}(\cdot)) + \text{Biais}(\hat{f}(\cdot)) + \text{Variance}(\hat{f}(\cdot)) \quad (1.7)$$

qui traduit le compromis biais-variance apparaissant dans la recherche du classifieur.

Le risque réel étant inconnu, la complexité optimale de la famille \mathcal{F} ainsi que le classifieur optimal au sein de \mathcal{F} sont recherchés à partir de la minimisation de l'erreur de généralisation du classifieur. Plusieurs critères d'optimalité peuvent être utilisés. Ils sont évoqués ci-après

Minimisation du risque empirique (MRE)

Une première approche consiste à approximer le risque réel du classifieur par le risque empirique sur le jeu d'apprentissage

$$\mathcal{R}_{\text{emp}}(\hat{f}(\cdot)) = \frac{1}{n} \sum_{i=1}^n \mathcal{L}(\omega_i, \hat{f}(x_i)) \quad (1.8)$$

1. dimension de Vapnik-Chervonenkis




FIGURE 1.2 – Les différents niveaux d'erreur de généralisation du classifieur.

La classification par MRE consiste à déterminer, parmi \mathcal{F} , le classifieur qui minimise (1.8) :

$$\hat{f}_{\text{emp}}(\cdot) = \underset{f \in \mathcal{F}}{\operatorname{argmin}} \mathcal{R}_{\text{emp}}(\hat{f}(\cdot)) \quad (1.9)$$

Le choix de l'espace fonctionnel \mathcal{F} joue un rôle déterminant sur la généralisation du classifieur. La généralisation n'est garantie que si le risque empirique est une approximation satisfaisante du risque réel. On peut montrer que si dans \mathcal{F} le risque empirique converge uniformément vers le risque réel, alors $\mathcal{R}(\hat{f}_{\text{emp}}(\cdot))$ converge en probabilité vers $\mathcal{R}(f_{\text{opt}}(\cdot))$. Cette convergence est vérifiée lorsque la dimension VC de \mathcal{F} est finie [Vapnik, 2000].

Minimisation du risque structurel

Le risque structurel tente d'établir un choix optimal de la complexité de \mathcal{F} , i.e., son adéquation avec le problème à résoudre. L'idée est de considérer un ensemble infini de familles emboîtées et de complexité croissante $\mathcal{F}_1 \subset \dots \subset \mathcal{F}_k \subset \dots$. En pratique, cet ensemble est cependant fini, mais de taille suffisante de manière à assurer que $f_{\text{Bayes}}(\cdot) \in \bigcup_k \mathcal{F}_k$. Le classifieur optimal est défini par

$$\hat{f}_{\text{emp}}(\cdot) = \underset{\substack{\hat{f} \in \mathcal{F}_k \\ k \in \mathbb{N}}}{\operatorname{argmin}} \mathcal{R}_{\text{emp}}(\hat{f}(\cdot)) + \operatorname{pen}(k, n) \quad (1.10)$$

où $\operatorname{pen}(k, n)$ est un terme pénalisant les modèles complexes (i.e. croissant avec k), mais d'autant moins que la taille du jeu d'apprentissage est grande (i.e. décroissant avec N) car une quantité illimitée de données d'apprentissage permettrait d'atteindre $\hat{f}_{\text{opt}}(\cdot)$. L'équation (1.10) propose une solution au compromis biais-variance (1.7). Le risque empirique et le biais structurel diminuent avec la complexité de \mathcal{F} , mais le terme de pénalisation (qui rend compte de la variance du classifieur) augmente.

Régularisation

Une autre manière de définir l'optimalité du classifieur est de considérer une famille \mathcal{F} large et de définir un terme de régularisation comme pénalisation de la complexité du classifieur. Celle-ci est généralement issue d'une mesure de la norme du classifieur sur \mathcal{F} . Le classifieur optimal est défini par

$$\hat{f}_{\text{emp}}(\cdot) = \underset{\hat{f} \in \mathcal{F}}{\operatorname{argmin}} \mathcal{R}_{\text{emp}}(\hat{f}(\cdot)) + \lambda \|\hat{f}(\cdot)\|^2 \quad (1.11)$$

où λ est le paramètre de régularisation. De cette manière, l'espace \mathcal{F} est susceptible de contenir $f_{\text{Bayes}}(\cdot)$, et le terme de régularisation tend à éviter le sur-apprentissage et à converger vers $\hat{f}_{\text{opt}}(\cdot)$. Notons qu'à la différence de (1.10) où la régularisation est liée à




FIGURE 1.3 – Évolution des erreurs d'apprentissage et de test en fonction de la complexité du classifieur.




FIGURE 1.4 – Principe de la validation croisée pour l'estimation de l'erreur de test. Illustration à l'ordre trois.

la complexité de \mathcal{F} , ici elle est directement liée au choix du classifieur dans \mathcal{F} . Cependant, la difficulté est reportée sur le choix optimal de λ .

La recherche de régularisation optimale repose sur l'utilisation d'un jeu de données annotées supplémentaires, appelées données test, indépendantes du jeu d'apprentissage. Le risque empirique sur le jeu test offre une meilleure approximation du risque réel et permet de valider le choix de la régularisation appliquée (cf. figure 1.3). La mise en œuvre pratique de l'estimation du risque réel est usuellement basée sur une validation croisée d'ordre K . L'ensemble des données est réparti aléatoirement en K sous-ensembles. $K - 1$ d'entre eux contiennent les données d'apprentissage, et le dernier contient les données tests. L'apprentissage est réitéré K fois, en interchangeant les données test. L'estimation du risque réel est alors obtenu par la moyenne de l'erreur de classification des données test. Le principe est illustré par la figure 1.4 pour la validation croisée d'ordre trois.

1.2.3 Modèles génératifs vs. discriminatifs

Des nombreux modèles de classifieurs supervisés ont été proposés dans la littérature. Une lecture concise et pédagogique des méthodes de classification les plus usuelles est disponible dans [Hastie et al., 2009]. L'objectif commun est de déterminer une règle de décision avec un taux d'erreur aussi faible que possible. La classification est systématiquement attachée à imiter $f_{\text{Bayes}}(\cdot)$ (1.2). Néanmoins, plusieurs approches de modélisation existent. Celles-ci peuvent être classées en deux grandes catégories, qui sont les modélisations générative et discriminative.

Approche générative

L'approche générative s'attache à modéliser la distribution $P(x, \omega)$ à partir de la connaissance a priori de $P(\omega)$ et en considérant l'apprentissage de la vraisemblance

$P(x | \omega)$ qui gouverne le comportement des données au sein de chaque classe. Cette approche permet l'utilisation naturelle du cadre probabiliste pour la reconnaissance. Les distributions $P(\omega)$ et $P(x | \omega)$ étant obtenues à partir des données d'apprentissage, la probabilité a posteriori requise pour la classification est déduite par inversion bayésienne :

$$P(\omega | x) = \frac{P(x | \omega)P(\omega)}{\sum_{\omega \in \Omega} P(x | \omega)P(\omega)} \quad (1.12)$$

Le classifieur est alors obtenu par maximum a posteriori (MAP)

$$\omega^* = \hat{f}(x) = \underset{\omega \in \Omega}{\operatorname{argmax}} P(\omega | x) \quad (1.13)$$

Il est appelé classifieur bayésien (en anglais : *naive Bayes classifier*) [Rish, 2001]. En l'absence d'a priori sur Ω , la probabilité $P(\omega)$ est généralement choisie uniforme. L'avantage de l'approche générative est que $\hat{P}(x | \omega)$ peut être appris séparément pour chaque classe. Cet apprentissage local permet l'ajout d'une nouvelle classe sans remettre en cause l'ensemble de la modélisation. Les fonctions d'approximation utilisées sont par exemple des fonctions de densité paramétriques continues sur l'espace de représentation \mathcal{X} . Une fois les paramètres estimés à l'aide des données d'apprentissage, la vraisemblance peut être obtenue pour toute observation $x \in \mathcal{X}$.

Les modèles génératifs sont utilisés dans de nombreux domaines, incluant les séries temporelles, les modèles de mélange, les modèles graphiques comme les champs de Markov, ou les modèles de Markov cachés. Une difficulté de la modélisation générative est liée à l'estimation des densités sous-jacentes qui fait face au phénomène bien connu de "fléau de la dimension" (en anglais : *curse of dimensionality*). Ce phénomène limite son utilisation à des dimensions très petites, et ce d'autant plus que la quantité de données est faible. Dans son livre, [Tarantola, 1987] évoque cette difficulté : "Lorsqu'une distribution de probabilité est définie sur un espace de petite dimension (c'est-à-dire entre deux et quatre dimensions), nous pouvons directement représenter la densité de probabilité associée. Cela est trivial en une ou deux dimensions. Cela est facile en trois dimensions, et quelques astuces peuvent nous permettre de représenter une distribution de probabilité en quatre dimensions. [...] Lorsqu'un espace de modèles a un grand nombre de dimensions, il est impossible de représenter une densité de probabilité. [...] Il y a un problème avec les espaces de grande dimension que l'on tend à sous-estimer : ils sont terriblement vides"². En faible dimension, la densité de probabilité peut être estimée à partir des données à l'aide de noyaux de convolution [Titsias et Likas, 2001; Morejon et Principe, 2004], ou de modèles de mélanges finis [McLachlan et Peel, 2000] généralement associés à une estimation de paramètres par l'algorithme espérance-maximisation (EM) [Dempster et al., 1977]. [Zegers et Johnson, 2006] réalisent l'estimation de la densité à l'aide d'un perceptron multi-couches. D'autres méthodes non paramétriques ont également été proposées (se référer à [Zegers et Johnson, 2006] pour une liste des principales références). En grande dimension, l'estimation des paramètres d'une distribution inconnue peut être effectuée par des méthodes de Monte Carlo [Tarantola, 1987]. Ces méthodes suivent cependant un objectif relativement différent de celui recherché, en étant avant tout destinées à capturer le comportement général de la distribution (moyenne, moments) sans chercher à prédire la vraisemblance d'un futur événement. Pour une lecture complémentaire sur l'estimation de la densité, le lecteur pourra également se référer à [Scott, 1992].

2. p. 42 : "When a probability distribution has been defined over a space of low dimension (say from one to four dimensions), we can directly represent the associated probability density. This is trivial in one or two dimension. It is easy in three dimension, and some tricks may allow us to represent a four dimensional probability distribution. [...] When a model space has a large number of dimensions, representing a probability density is impossible. [...] There is one problem with large-dimensional spaces that is easy to underestimate : they tend to be terribly empty."

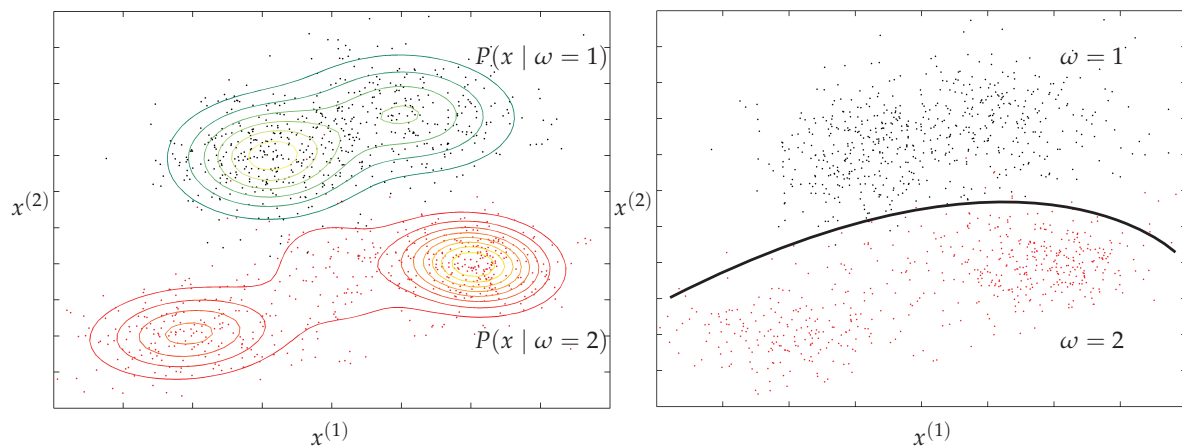


FIGURE 1.5 – Classification binaire par approche générative (gauche) et discriminative (droite) en deux dimensions.

Approche discriminative

L'approche discriminative modélise directement le classifieur issu de la probabilité a posteriori $P(\omega | x)$ à partir des données d'apprentissage, sans chercher à estimer $P(\omega | x)$ elle-même. En d'autres termes, une cartographie directe entre l'entrée x et la classe ω est apprise. En s'attachant uniquement à déterminer les frontières entre les classes dans l'espace de représentation, cette approche est plus proche de l'objectif final. Elle peut généralement être appliquée pour des dimensions plus importantes que l'approche générative ([Lowe, 2004; Lazebnik et al., 2006]). La différence de modélisation entre les approches générative et discriminative est illustrée par la figure 1.5. Un large panel de modèles discriminatifs a été proposé depuis l'essor de l'intelligence artificielle. Les principaux sont énumérés ci après.

- L'approche discriminative la plus simple est la classification par les K plus proches voisins (K -ppv) [Dasarathy, 1990], qui ne nécessite aucun modèle à estimer. Une nouvelle donnée est classée en mesurant sa distance aux K données d'apprentissage les plus proches et en attribuant la classe majoritairement représentée. La simplicité de ce classifieur ne préjuge pas de son efficacité. Il est susceptible d'atteindre des performances comparables à des techniques plus sophistiquées lorsque la mesure de distance est choisie convenablement [Zhang et al., 2006].
- Les réseaux de neurones [Ripley, 2008], formés par l'agencement d'un ensemble de fonctions d'activation paramétriques, sont appris par optimisation itérative des paramètres. Le sur-apprentissage est évité en limitant le nombre d'itérations ou en ajoutant un terme d'amortissement de l'évolution des paramètres au cours de l'apprentissage.
- La régression logistique est un classifieur basé sur une approximation du log-ratio des probabilités a posteriori par une fonction affine. La faible complexité de cette approximation limite le sur-apprentissage.
- Les arbres de décision, dont les algorithmes les plus connus sont CART [Breiman et al., 1984] et C4.5 [Quinlan, 1993], sont basés sur un découpage récursif des données dans l'espace de représentation selon un critère d'optimalité. Le sur-apprentissage est évité à l'aide de méthodes d'élagage des arbres, ou bien en considérant une forêt d'arbres très peu complexes formant un comité de décision (en anglais : *bagging*) pour réduire la variance [Breiman, 1996]. Ce principe de comité est également à la base des classifieurs par forêts aléatoires [Breiman, 2001].
- Les méthodes par boosting [Schapire et al., 1998] sont elles aussi basées sur une réunion de classifieurs faibles. Mais l'estimation de chacun d'entre eux est réalisée itérativement, basée sur une pondération des données d'apprentissage avant le calcul

de l'erreur de classification. Les classifieurs faibles peuvent être issus de n'importe quelle technique de classification. Le sur-apprentissage est évité en limitant le nombre d'itérations ou par des méthodes d'amortissement (en anglais : *shrinkage*) [Friedman, 2001].

- Les machines à vecteurs support ou SVM (en anglais : *Support Vector Machines*) [Vapnik, 2000] font partie des classifieurs dits à noyau. L'objectif est de maximiser la marge, c'est-à-dire la distance entre la frontière de décision et la donnée d'apprentissage la plus proche. Un paramètre de régularisation apparaît explicitement dans l'optimisation. Le choix d'un noyau non linéaire (par exemple gaussien) permet d'envisager les SVMs comme une estimation de fonction dans un espace de Hilbert à noyau reproduisant, conduisant à des frontières de décision complexes [Muller et al., 2001; Schölkopf et Smola, 2002].

De nombreux arguments favorisent l'approche discriminative pour la classification, appuyés par [Vapnik, 2000] : "Si vous êtes limité à une quantité d'information restreinte, ne résolvez pas le problème particulier [de classification] en résolvant un problème plus général"³. Néanmoins, chacune des deux approches apporte à la fois des avantages et des inconvénients. [Ng et Jordan, 2002] ont constaté que, sous l'hypothèse d'une distribution sous-jacente gaussienne des données, l'approche bayésienne générative par analyse discriminante linéaire (ADL) conduit à une erreur asymptotique plus importante que par la version discriminative par régression logistique. La convergence est cependant plus rapide. Ce biais de l'erreur lié à l'approche générative est également souligné par [Bouchard et Triggs, 2004].

Cependant, les modèles génératifs conduisent généralement à une variance faible. Pour des ensembles finis de données d'apprentissage, le compromis biais-variance ne semble donc favoriser aucune des deux approches [Bouchard et Triggs, 2004; Ulusoy et Bishop, 2006]. C'est pourquoi plusieurs travaux ont proposé des modélisations mixtes dans lesquelles les avantages des approches génératives et discriminatives tendent à être rassemblés. [Jaakkola et Haussler, 1999] utilisent le noyau de Fisher pour réaliser un apprentissage discriminatif à partir d'une modélisation générative. [Bouchard et Triggs, 2004] introduisent une nouvelle fonction objectif permettant une interpolation continue entre les fonctions objectifs générative et discriminative. Le paramètre de cette interpolation est estimé à partir de l'erreur de classification par validation croisée. [Raina et al., 2004] proposent un modèle hybride dans le cas de la classification de documents textuels. En reconnaissance d'objets, [Ulusoy et Bishop, 2006] comparent les deux approches et discutent des possibilités de leur combinaison, tandis que [Deselaers et al., 2010] proposent de combiner un modèle de mélange gaussien aux SVMs pour améliorer leur généralisation.

1.2.4 Extension au cas multi-classes

Les techniques de classification présentées dans la section précédente sont applicables au cas binaire. Celui-ci n'est cependant qu'un cas particulier de la classification multi-classes. La classification multi-classes est définie par une variable aléatoire de sortie ω à valeur dans $\Omega = \{1, \dots, \mathcal{K}\}$ où \mathcal{K} est le nombre de classes. Certains classifieurs s'étendent naturellement à un nombre de classes plus élevé, alors que d'autres nécessitent une étape supplémentaire d'extension. Ces méthodes sont ici présentées.

Classifieurs généralisables au multi-classes

Parmi les classifieurs décrit précédemment, plusieurs d'entre eux peuvent s'étendre directement au multi-classes. Cette extension peut être réalisée spontanément ou bien à partir d'une reformulation du problème d'optimisation sous-jacent. Cette catégorie de classifieurs

³ p. 293 : "If you are limited to a restricted amount of information, do not solve the [classification] problem you need by solving a more general problem".

inclut le classifieur par K -ppv, le classifieur par MAP (équation (1.13)), les arbres de décision, les réseaux de neurones, les SVMs, et les classifieurs par boosting.

- L'extension pour les deux premiers classifieurs cités est triviale.
- Dans le cas des arbres de décision, les critères de découpage des données étant eux-mêmes extensibles (voir [Hastie et al., 2009] pour des exemples de critères), chaque feuille attribue la classe majoritairement représentée par les données d'apprentissage lorsqu'une nouvelle donnée lui parvient.
- Les réseaux de neurones s'étendent au cas multi-classes en remplaçant l'unique neurone de la couche de sortie par N neurones. Deux cas de figure apparaissent [Dietterich et Bakiri, 1995] : (i) chaque neurone est spécialisé pour une classe, i.e. renvoie 1 si la nouvelle donnée appartient à la classe correspondante, 0 sinon. Dans ce cas, $N = \mathcal{K}$; (ii) un code binaire spécifique est attribué à chaque classe et le réseau apprend de manière à renvoyer le code correct. Pour N neurones en sortie, 2^N classes peuvent être discriminées. En pratique, une distance de Hamming est définie entre le code de sortie et le code de chaque classe, et la classe la plus proche est attribuée. Ces codes correcteurs d'erreur, suggérés par [Dietterich et Bakiri, 1995], se sont montrés également efficaces en combinaison avec le classifieur C4.5.
- Les SVM peuvent également être étendus à partir d'une reformulation du problème d'optimisation et d'une fonction de perte incluant l'ensemble des classes [Weston et Watkins, 1999; Crammer and Singer, 2002].
- Dans le cas de la classification par boosting, une version multi-classes de l'algorithme Adaboost, l'algorithme SAMME, a été proposé par [Zhu et al., 2006]. Celui-ci est basé sur une reformulation de la fonction de perte.

Notons que la reformulation d'une fonction de perte pour l'extension au multi-classes (notamment pour le SVM et le boosting) doit conduire, comme pour le cas binaire, à la consistance du classifieur. Un ensemble de conditions pour la consistance ainsi qu'une analyse de plusieurs classifieurs multi-classes existants ont été proposés par [Tewari et Bartlett, 2007].

Décomposition en classifieurs binaires

Une seconde approche pour obtenir un algorithme de classification multi-classes consiste à apprendre une série de classifieurs binaires et de combiner l'ensemble des sorties. Cette technique est très utilisée car elle est généralement facile à mettre en œuvre. La combinaison de classifieurs binaires peut être réalisée de plusieurs manières.

Stratégie un contre tous. Cette stratégie consiste à considérer l'apprentissage du classifieur sur \mathcal{K} classes comme l'apprentissage de \mathcal{K} classifieurs binaires. Chacun d'entre eux permet de discriminer une classe parmi l'ensemble des classes restantes. Lors de la classification d'une nouvelle donnée, chaque classifieur apporte sa contribution sur l'inférence finale. Deux manières de dériver le classifieur final sont généralement rencontrées. Dans la première, le classifieur binaire produisant la valeur la plus grande est considéré vainqueur et la classe correspondante est attribuée. Dans la deuxième, chacun des \mathcal{K} classifieurs vote soit pour la classe qu'il discrimine, soit pour l'ensemble des autres classes. La classe ayant remporté le plus de votes est alors attribuée.

Stratégie un contre un. Étudiée par [Hastie et Tibshirani, 1998], et parfois appelée stratégie *tous contre tous* ou *toutes-paires*, elle consiste en l'apprentissage de $\binom{\mathcal{K}}{2}$ classifieurs binaires. Pour chacun d'entre eux, seules des données d'apprentissage de deux classes distinctes sont considérées. Lors de la classification, chaque classifieur vote pour l'une des deux classes qu'il considère, et la décision finale est obtenue par vote majoritaire.

Généralisation de ECOC. La décomposition d'un classifieur multi-classes en un ensemble de classifieurs binaires est considérée de manière plus générale par [Allwein et al.,

2001]. La stratégie ECOC est étendue aux classifieurs à marge, dont SVM et Adaboost, et la distance de Hamming utilisée pour comparer les codes binaires est remplacée par une distance basée sur une fonction de perte. Cette distance permet de tenir compte de la marge des classifieurs binaires (qui est synonyme de confiance en la classification) dans la décision finale.

Classification hiérarchique. Une troisième approche pour la classification multi-classes utilise une série de classifieurs binaires organisés en arbre et permettant de séparer progressivement les classes jusqu'à ce que chaque feuille ne contienne qu'une seule classe. Le découpage en sous-ensembles de classes doit être tel que l'erreur de classification du nœud correspondant soit la plus faible. Cette minimisation est généralement garantie par l'utilisation de mesures indirectes de la séparabilité des sous-ensembles. Dans [Kumar et al., 2002], le critère est la maximisation du score de Fisher. [Chen et al., 2004] fait intervenir la distance de Kullback-Leibler, et [Madzarov et al., 2009; Vural et Dy, 2004] réalisent des agglomérations par l'algorithme K -means pour construire une hiérarchie de classifieurs SVMs.

1.3 REPRÉSENTATION DES OBJETS POUR LA RECONNAISSANCE

Les techniques de classification supervisée présentées dans la section précédente ont été basées sur l'hypothèse que les données, décrites par le vecteur descripteur x appartenant à un espace vectoriel de dimension finie, contiennent toute l'information nécessaire à l'inférence. La problématique de description des données brutes en un vecteur exploitable pour la classification est abordée dans cette section. Le cas particulier de la description des images, où les données brutes sont les pixels, est considéré ici. Les différents paradigmes et les techniques de description associées, apparus dès la naissance de l'intelligence artificielle dans les années 1950, sont présentés. Des ouvrages de référence tels que [Ponce, 2006] permettront au lecteur d'approfondir l'état de l'art proposé.

1.3.1 Perception, invariance et reconnaissance

La reconnaissance est basée sur l'état perçu de l'objet. La notion de perception est centrale à la problématique de description des objets. Que décrire et comment? Bien que la qualité de la description conditionne le résultat de l'application sous-jacente, le contexte de l'application lui-même est également un facteur de choix d'une stratégie de description. La représentation cognitive des objets est différente d'une représentation efficace pour un algorithme de reconnaissance [Edelman, 1997; Campbell et Flynn, 2001]. Par exemple, le processus de reconnaissance par l'humain semble suivre une approche "top-down" [Posner et Keele, 1968; Biederman, 1987], basée sur des a priori et une représentation abstraite des objets. Cela permet de les reconnaître sous des poses et des apparences variables et de catégoriser un nouvel objet non appris. À l'inverse, un algorithme de reconnaissance est basé sur une approche "bottom-up" [Rutishauser et al., 2004], bien que des travaux récents ont tenté d'extraire et de comparer une représentation plus abstraite des objets, par exemple par l'intermédiaire de graphes de représentation [Ozcanli et al., 2006; Harchaoui et Bach, 2007]. Des métriques fines et quantifiables par la machine telles que la disposition des contours, leur courbure locale ou leur orientation, sont extraites et utilisées par l'inférence, bien que peu révélatrices pour un individu. Le choix des caractéristiques mesurées est un problème clé de la représentation. Dans l'une des premières revues des techniques de représentation des objets, [Brown, 1981] suggère que les propriétés de non-ambiguïté, de concision et d'unicité dans la perception des objets devraient être vérifiées pour la reconnaissance automatique. La non-ambiguïté mesure la capacité de la représentation à discriminer les classes entre elles. La concision s'attache à l'efficacité calculatoire de la représentation. Les images sont des données naturellement de grande dimension et




FIGURE 1.6 – Illustration de la variance inter-classes (V_{inter}) et intra-classe (V_{intra}).

nécessitent une représentation capable de réduire celle-ci. L'unicité garantit que la stratégie de représentation conduit à un modèle unique.

Les différences d'apparence des objets au sein d'une même classe, dues à des changements d'illumination, des déformations des objets, des occultations partielles, des changements d'échelle ou au bruit conduisent à une variance intra-classe devant être réduite. À l'inverse, les changements d'apparence entre deux classes conduisent à une variance inter-classes devant être grande. Cette différence de traitement entre ces variances doit être garantie par le descripteur. Elle est illustrée par la figure 1.6.

La validation simultanée des propriétés précédentes a conduit à l'identification des transformations et à la recherche d'invariants de description [Weiss, 1992; Forsyth et al., 1991]. Cependant, une invariance du descripteur à l'ensemble des transformations au sein d'une classe sans a priori sur les objets est très difficile à atteindre. En particulier, des caractéristiques invariantes par rotation 3D n'existent pas sans connaissance a priori sur les modèles [Burns et al., 1992; Moses et Ullman, 1992; Rothwell et al., 1993; Tarr et al., 1998]. Elle n'est pas non plus toujours souhaitable car une augmentation de l'invariance conduit souvent à une augmentation de l'ambiguïté [Weiss, 1992; Schiele et Crowley, 1996]. Le degré d'invariance optimal du descripteur pour la reconnaissance est un choix délicat et dépendant du problème à résoudre. Il peut être issu d'a priori et/ou être appris à l'aide des données [Varma et Ray, 2007].

1.3.2 Modélisation 2D

Du fait de la difficulté à obtenir une représentation invariante par rotation 3D de l'objet (i.e. invariante par projection), une vaste majorité des applications en reconnaissance d'objet repose sur l'hypothèse d'une pose de l'objet observé connue a priori. L'invariance du descripteur par projection n'est alors plus recherchée. Néanmoins, d'autres variations telles les petites variations de pose, de position, les changements d'échelle ou les rotations dans le plan demeurent. Cette section liste et retrace l'évolution des descripteurs pour une modélisation et une reconnaissance 2D des objets. La modélisation 3D est reportée en section 1.3.3.

Descripteurs géométriques

L'étude des groupes de transformations géométriques et de leur invariance est ancienne. Une étude théorique rigoureuse est disponible dans [Weyl, 1997]. L'application d'invariants géométriques pour la reconnaissance fut naturellement l'une des premières mise en œuvre.

La reconnaissance est basée sur l'appariement d'un modèle géométrique avec des caractéristiques bas niveau extraites des images, telles que les contours, des points, des courbes, des segments. Cette reconnaissance "basée-modèle" par appariement a connu un essor particulier dans le cas de modèles géométrique 3D. Celui-ci est reporté en section 1.3.3. Elle est également mise en œuvre pour la reconnaissance d'objets plans [Huttenlocher et Ullman, 1987; Lamdan, 1988]. Les caractéristiques de bas niveau forment la silhouette de l'objet (en anglais : *shape*). La silhouette offre une représentation géométrique beaucoup plus compacte que l'image initiale, robuste aux occultations, tout en conservant une information structurelle de l'objet. Les éléments constituant la silhouette restent cependant nombreux et sont peu caractéristiques de l'objet lui-même. Une tentative d'appariement directe sous l'ensemble des transformations possibles (changement d'échelle, rotation...) conduirait à une combinatoire trop importante. Des propriétés structurelles caractéristiques de l'objet peuvent être sélectionnées préalablement pour réduire la complexité. [Biederman, 1987] qualifie ces propriétés de "non-accidentelles". Elles incluent les symétries, les courbures, les colinéarités, les parallélismes, ou encore les terminaisons de contours. Ces propriétés peuvent être définies a priori [Nelson et Selinger, 1998] ou sélectionnées par apprentissage supervisé [Shotton et al., 2005; Opelt et al., 2006]. Des stratégies d'appariement peuvent également être mises en œuvre pour limiter la complexité, comme la stratégie de génération et validation d'hypothèses [Huttenlocher et Ullman, 1987; Lamdan, 1988] ou bien par l'utilisation de solveurs efficaces [Berg et al., 2005]. L'appariement nécessite également la définition d'une métrique associée à la silhouette. De nombreux exemples de métriques sont donnés par [Veltkamp et Hagedoorn, 2001] à travers un état de l'art sur l'appariement d'objet par leur silhouette.

L'extraction de la silhouette à partir des images (i.e. de l'intensité des pixels) a donné lieu à de nombreux travaux. Des détecteurs de contours robustes aux changements d'illumination et de contraste ont été proposés. Le plus connu est le détecteur de Canny-Deriche [Canny, 1987; Deriche, 1990]. D'autres méthodes plus sophistiquées existent, mais l'amélioration apportée est souvent au prix d'une complexité accrue [Freeman et Adelson, 1991; Da et Zhang, 2010; Lopez-Molina et al., 2010].

Les contours fortement anguleux, aussi appelés "coins", sont des points d'intérêt ayant également donné lieu à des détecteurs spécifiques. Le plus populaire est le détecteur de [Harris et Stephens, 1988], basé sur l'auto-corrélation sur une fenêtre glissante. Une approximation des contours par des courbes paramétriques suivie d'une mesure de courbure locale est utilisée par [Lynn Beus et Tiu, 1987; Medioni et Yasumoto, 1987]. La répétabilité et l'information contenue par les coins détectés sont les critères recherchés. Ces critères sont évalués et comparés pour plusieurs détecteurs par [Schmid et al., 2000].

D'autres propriétés de la silhouette peuvent également être utiles à la reconnaissance. [Jurie et Schmid, 2004] proposent un détecteur basé sur une mesure de concavité des contours, et [Kadir et Brady, 2001] mesurent les maxima d'entropie de la distribution d'intensité des pixels sur des régions circulaires. Ces méthodes permettent toutes deux d'extraire les dispositions en cercles à des échelles variées. D'autres travaux mettent en œuvre une description statistique issue de l'information géométrique [Evans et al., 1993; Bosch et al., 2007; Ferrari et al., 2008].

Descripteurs d'apparence

Une description géométrique des objets n'est pas toujours suffisante pour capturer l'information nécessaire à la reconnaissance [Grimson et al., 1990]. L'information complémentaire à la silhouette est l'apparence. Elle permet de capturer les variations faibles d'intensité négligées par les détecteurs de contours, ainsi que d'autres informations comme la couleur ou l'intensité des pixels. Un autre inconvénient de la reconnaissance basée modèle est la nécessité d'une connaissance a priori du modèle (polygones, courbes paramétriques). La construction des modèles peut être difficile lorsque la silhouette est complexe, ou fastidieuse lorsque le nombre de classes est élevé. Un système de reconnaissance capable de

modéliser de manière autonome par apprentissage sur les données est préférable, et une description d'apparence est susceptible d'être plus adaptée [Nayar et al., 1996].

Les histogrammes ont été largement utilisés pour décrire l'apparence des objets. Leur mise en œuvre remonte à [Swain et Ballard, 1991] dans une description par la couleur. D'autres informations, comme l'orientation du gradient [Lowe, 2004] ou l'intensité des pixels [Hadjidemetriou et al., 2004] sont également représentées sous forme d'histogrammes. Ils sont utilisés dans la plupart des applications en vision par ordinateur, comme la détection [Dalal et Triggs, 2005; Laptev, 2006], le suivi [Yilmaz et al., 2006] ou encore la reconnaissance [Schiele et Crowley, 1996; Harchaoui et Bach, 2007]. Ils ont l'avantage d'être rapides à calculer [Porikli, 2005] tout en diminuant la dimension initiale de l'image. Ils sont également robustes aux variations de pose, de rotation, et aux occultations [Swain et Ballard, 1991; Schiele et Crowley, 1996].

Approche globale. Dans une description globale, l'ensemble de l'image est considéré pour représenter l'objet. Cela permet de ne négliger aucune information susceptible d'être utile pour la reconnaissance. La description peut être effectuée en chaque pixel [Schiele et Crowley, 1996; Tola et al., 2008; Winn et al., 2005], sur une grille régulière [Lazebnik et al., 2006], sur des points d'intérêt [Csurka et al., 2004] ou encore de manière aléatoire [Marée et al., 2004]. Chaque pixel peut être décrit de manière simple (par exemple par ses dérivées) ou en considérant un voisinage plus étendu par le biais d'un descripteur d'apparence local (une revue intéressante de plusieurs descripteurs et la comparaison de leurs performances est donnée dans [Mikolajczyk et Schmid, 2005]). Un cas particulier est le descripteur DAISY [Tola et al., 2008], inspiré du descripteur SIFT [Lowe, 2004], consistant en une description locale dense (en chaque pixel) et efficace grâce à une série de convolutions rapides. Cette description locale dense conduit à un descripteur global de dimension proche, voire beaucoup plus importante que la dimension initiale de l'image. Bien que non utilisable directement pour la classification, une telle description possède les propriétés d'invariance liées à l'utilisation des histogrammes.

Les représentations denses et de grande dimension ont été motivées avec l'apparition des descripteurs par "sac de mots" (en anglais : *bag of words*) [Csurka et al., 2004], basés sur l'utilisation d'un vocabulaire visuel compact extrait des images d'apprentissage. La capacité de généralisation de ce descripteur en fait l'un des plus utilisés dans l'état de l'art actuel [Winn et al., 2005; Lazebnik et al., 2006; Ozuysal et al., 2009; Jegou et al., 2007], et est en constante amélioration, notamment dans la construction de dictionnaires efficaces [Jurie et Triggs, 2005; Moosmann et al., 2007] ou dans la recherche de stratégies d'échantillonnage efficaces [Nowak et al., 2006].

Dans leur approche initiale, les descripteurs globaux (qu'ils soient basés sur l'apparence ou la silhouette) offrent une description vectorielle simple. Cependant, ils représentent l'image comme une statistique désordonnée d'indices et ne permettent pas de capturer leur distribution spatiale, également utile pour la reconnaissance. Pour pallier cette absence de structure, une représentation globale formée par l'agrégation de descripteurs calculés en des sous-régions fixes de l'images a été suggérée par [Lazebnik et al., 2006] sous le nom de pyramide spatiale de représentation. Cette stratégie avait plus tôt été mise en œuvre dans les descripteurs d'apparence locaux [Mikolajczyk et Schmid, 2005]. En ordonnant spatialement la statistique globale, la structure est indirectement contenue dans la représentation, offrant des performances de reconnaissance supérieures. Le descripteur PHOG [Bosch et al., 2007] est directement inspiré de cette représentation. Le choix de la localisation des descripteurs d'apparence locale peut également être guidée par la silhouette de l'objet [Ozcanli et al., 2006; Harchaoui et Bach, 2007]. La structure de l'objet est mieux capturée, au prix d'une complexité de description accrue.

Approche locale. À la différence de l'approche globale, l'approche locale ne considère qu'une partie de l'image dans la représentation. [Schmid et Mohr, 1997] furent parmi les

premiers à proposer une reconnaissance d'objet basée sur une description locale. Les zones décrites (en anglais : *patches*), aussi appelées parts, composants, ou fragments, sont locales et éparées. Les avantages liés à cette approche sont multiples. D'une part, elle permet une représentation compacte focalisée sur les zones utiles de l'objet et permettant une discrimination d'objets basée sur des différences très locales [Epshtein et Ullman, 2006]. Elle est également robuste aux occultations partielles, aux déformations et aux variations inter-classes. La représentation locale permet d'envisager une description efficace même lorsque les objets n'occupent qu'une partie de l'image et le fond est prépondérant.

L'invariance de la représentation est liée à l'invariance des descripteurs locaux. La recherche de points d'intérêt stables a été abordée au paragraphe précédent par le biais de détecteurs de points d'intérêt. Le principe d'une description invariante par changement d'échelle remonte à [Koenderink, 1984] avec l'introduction d'un espace d'échelle des images. La sélection de l'échelle optimale des descripteurs locaux fut en premier lieu étudiée dans les travaux fondateurs de [Lindeberg, 1993], dans lesquels un espace d'échelle de l'image est introduit via des convolutions successives avec un noyau dérivatif gaussien. Dans [Lindeberg, 1998], la recherche de maxima à la fois spatialement sur l'image et sur l'espace d'échelle d'une mesure basée sur les dérivées normalisées conduit à un détecteur LoG (Laplacian of Gaussien) ainsi qu'un détecteur basé sur l'opérateur de Monge-Ampère (le déterminant de la matrice hessienne). Celui-ci permet une détection à la fois de points d'intérêt (appelés blobs) et de leur échelle caractéristique, i.e. une région locale invariante par changement d'échelle. Un espace d'échelle est également utilisé par [Lowe, 1999]. Les maxima d'une mesure DoG (Difference of Gaussian) sur cet espace permettent d'extraire efficacement les points d'intérêt et leur échelle caractéristique. Cette méthode est à l'origine du très populaire descripteur SIFT [Lowe, 2004]. [Mikolajczyk et Schmid, 2001] proposent quant à eux le détecteur Harris-Laplace, basé sur le détecteur de coin de Harris qui est complémentaire au détecteur de blobs, et suivi d'une maximisation du laplacien pour déterminer l'échelle. Le détecteur MSER [Matas et al., 2004] base son invariance aux changements d'échelle à partir de la recherche de régions d'intensité similaires. [Kadir et Brady, 2001] proposent une recherche d'échelle caractéristique à partir d'une mesure d'entropie de la distribution locale d'intensité des pixels.

Les variations de pose des objets, qui contribuent à la variance intra-classe, s'apparentent localement à des transformations affines si l'on considère les régions locales comme planes. Ces approches consistent d'abord à détecter des points d'intérêts, puis à associer une description locale invariante. [Berg et Malik, 2001] améliorent la robustesse aux transformations affines d'une mesure de corrélation en considérant, pour chaque région décrite, un flou d'autant plus élevé que le pixel est éloigné du point d'intérêt. Pour obtenir une robustesse plus importante, une famille de descripteurs locaux invariants par transformation affine a été proposée. [Tuytelaars et Van Gool, 1999] furent parmi les premiers à considérer une région locale carrée sur la surface de l'objet et centrée sur un point d'intérêt, qui est déformée sous l'effet du changement pose et apparaît sur l'image sous la forme d'un parallélogramme. Les caractéristiques du parallélogramme sont évaluées à partir des contours de part et d'autre du point d'intérêt. Cette méthode est améliorée dans [Tuytelaars et Van Gool, 2000], en basant l'estimation des paramètres d'une ellipse sur la distribution radiale d'intensité et en considérant comme points d'intérêt les maxima locaux d'intensité qui, à la différence des coins, appartiennent généralement à des surfaces planes de l'objet. [Baumberg, 2000] adapte la région de description à la structure de l'image par le biais d'une procédure itérative basée sur la matrice des moments d'ordre deux [Lindeberg et Garding, 1997]. Cette procédure itérative est également mise en œuvre par [Mikolajczyk et Schmid, 2004] pour définir les paramètres de la dérivation gaussienne dans chaque direction et ainsi rendre un détecteur Harris-Laplace invariant par transformation affine. [Kadir et Brady, 2003] adaptent le descripteur invariant par changement d'échelle de [Kadir et Brady, 2001] en ajoutant dans l'espace de recherche du maxima d'entropie

une dimension supplémentaire pour prendre en compte une région elliptique autour du point d'intérêt.

De nombreux autres descripteurs locaux ont été proposés, chacun présentant des propriétés et des invariances spécifiques. Nous pouvons citer le descripteur "shape-context" [Belongie et al., 2001] basé sur des statistiques locales de la silhouette; "spin image" [Johnson et Hebert, 1997] qui, à partir de l'information 3D de la scène, permet une invariance à de larges variations de pose; GLOH [Mikolajczyk et Schmid, 2005], qui est une extension de SIFT; les corrélogrammes binaires (CSBC) [Amores et al., 2007] ou encore des descripteurs invariants par déformation des objets [Ling et Jacobs, 2005]. Une revue comparative de plusieurs descripteurs locaux est disponible dans [Mikolajczyk et Schmid, 2005; Moreels et Perona, 2007].

Les zones de description idéales ne sont pas nécessairement issues des points d'intérêt (coins, blobs), et leur taille optimale n'est pas nécessairement issue d'une analyse dans l'espace d'échelle. Elles dépendent de l'application sous-jacente. Pour la détection, [Torralba et al., 2007] propose une sélection des zones d'apparence communes entre les objets. La taille et la localisation des zones sont sélectionnées à partir de l'erreur de détection. L'erreur de classification est aussi utilisée par [Heisele et al., 2002] dans le cadre de la détection de visages. Pour la reconnaissance, [Ullman et al., 2002; Fergus et al., 2003; Epshtein et Ullman, 2005a] utilisent un critère de sélection des zones basé sur l'entropie qui mesure indirectement l'utilité pour la classification. [Epshtein et Ullman, 2005b; Ullman et Epshtein, 2006; Leibe et al., 2008] définissent les zones optimales comme représentatives d'un élément sémantique de l'objet (roue, phare...) et proposent des méthodes de sélection associées, tandis que [Moosmann et al., 2006] construisent des cartes d'utilité des zones à partir d'un classifieur par forêts aléatoires.

La reconnaissance par les descripteurs locaux peut être mise en œuvre dans le cadre de modèle d'apparence seul [Viola et Jones, 2001; Dorkó et Schmid, 2003], ou par le biais d'une représentation mixte par apparence et géométrie, décrite ci-après.

Descripteurs mixtes

Les descripteurs mixtes représentent l'objet par la combinaison d'une information d'apparence et d'une information géométrique. Ils regroupent les modèles de constellation, formés par un ensemble de zones de descriptions locales d'apparence reliées entre elles par des contraintes géométriques. Le paradigme des modèles de constellations peut être attribué à [Fischler et Elschlager, 1973]. [Amit et Geman, 1999; Burl et al., 1998] ont posé les bases d'un formalisme de reconnaissance probabiliste à partir de zones locales. Ce n'est qu'un peu plus tard que l'intérêt pour cette approche s'est développé.

Les contraintes géométriques sont de natures variables selon l'application considérée. Elles peuvent être définies par une distribution de probabilité [Fergus et al., 2003; Felzenszwalb et Huttenlocher, 2005; Amit et Trouvé, 2007] ou apprises par un classifieur [Heisele et al., 2002]. Elles sont généralement flexibles pour prendre en compte les déformations parfois importantes des objets. De plus, celles-ci sont souvent simplifiées car une dépendance géométrique exhaustive entre les zones conduirait à une explosion combinatoire. Les différentes stratégies de simplification sont illustrées dans [Carneiro et Lowe, 2006]. La plupart reposent sur un principe de reconnaissance en trois étapes [Moreels et al., 2004; Ferrari et al., 2006; Crandall et al., 2006] : (i) sélection de zones candidates à partir de l'apparence, (ii) génération d'hypothèses sur l'objet par application des contraintes géométriques sur une partie des patches, et (iii) vérification de l'hypothèse en intégrant le reste des zones et leur contraintes géométriques. Une stratégie très utilisée consiste à définir une zone référence et à exprimer les contraintes géométriques relatives entre cette zone et les autres. La zone de référence peut être réelle (i.e. avec une apparence) [Epshtein et Ullman, 2006] ou virtuelle, désignant par exemple le centre de l'objet prédite par les zones dans une approche appelée modèle de silhouette implicite (en anglais : *implicit shape model* ou ISM)

[Leibe et al., 2004; Fergus et al., 2005; Moreels et Perona, 2008].

L'invariance des modèles de constellation par changement d'échelle, ainsi que leur aspect local permettent d'estimer, en plus de la classe, à la fois la localisation et l'échelle de l'objet.

Notons enfin que les représentations globales par pyramide spatiale [Lazebnik et al., 2006; Bosch et al., 2007] peuvent être considérées comme un cas particulier des modèles de constellation, dans lequel les zones et les contraintes géométriques sont fixées arbitrairement et identiques pour tous les objets.

1.3.3 Modélisation 3D

La reconnaissance d'objets 3D à partir d'images est un problème intrinsèquement mal posé et nécessite l'introduction de contraintes pour le résoudre. Plusieurs approches ont été proposées pour réduire le fossé entre la réalité 3D des objets et leur représentation 2D. Une représentation 3D explicite peut être utilisée par le biais de modèles paramétriques 3D ou de modèles synthétiques constitués de voxels. Une autre manière très répandue est de modéliser implicitement la perspective manquante à l'aide d'une collection d'images sous des CPDV variées. Cette dernière approche, également appelée représentation 2,5D, serait proche de la perception des objets par l'humain [Marr, 1983; Bülthoff et Edelman, 1992]. Ces deux approches sont abordées ci-après.

Descripteurs structurels

La description géométrique des objets mise en œuvre pour la reconnaissance 2D (section 1.3.2) fait partie d'une approche beaucoup plus globale où l'objectif est d'extraire la structure 3D de l'objet à partir d'une observation 2D pour en effectuer la reconnaissance quelles que soient les CPDV. On les appelle descripteurs structurels. Ils reposent sur le paradigme initial d'une représentation haut niveau, par analogie avec la perception des objets par l'homme, et dans laquelle l'apparence ne joue qu'un rôle secondaire pour la reconnaissance [Biederman, 1987]. L'avantage de cette approche basée-modèle réside dans une prise en compte explicite des CPDV, qui permet, en plus de la reconnaissance, d'estimer la pose des objets. Les premiers travaux sur l'appariement des CPDV de l'objet avec les paramètres d'un modèle remontent à [Roberts, 1963]. Les travaux de [Shapira et Freeman, 1978] sont également précurseurs de l'approche basée-modèle, en proposant un cadre de modélisation à partir d'un ensemble de projections de l'objet. Le principe de reconnaissance se déroule en trois étapes : (i) extraction des caractéristiques de bas niveau, (ii) calcul des invariants (géométriques), puis (iii) appariement au modèle, robuste aux occultations partielles, par résolution d'un système d'équations. Les modèles sont généralement des formes géométriques simples tels que des polyèdres [Huttenlocher et Ullman, 1990; Lowe, 1991; Koller et al., 1993; Rothwell et al., 1993; Kollnig et Nagel, 1995; Li et al., 2008], ou un ensemble de formes élémentaires appelé grammaire qui permet une variété d'interprétations selon l'agencement des éléments [Lowe, 1987]. L'intérêt particulier pour les modèles polyédriques est dû à l'exploitation de contraintes géométriques (telles que des jonctions d'arrêtes ou des angles entre les arrêtes) qui limitent fortement le nombre de configuration possibles sous des CPDV données. [Huttenlocher et Ullman, 1990] ont montré que la configuration des polyèdres était unique (à une symétrie près) par l'appariement de six points dans l'image, et [Rothwell et al., 1993] proposent, sous certaines hypothèses, une méthode d'appariement des polyèdres à partir de huit points ou quatre points et deux droites.

Modèles d'apparence

La reconnaissance 3D basée-modèle souffre des mêmes inconvénients que dans le cas 2D. La construction des modèles géométriques nécessite une connaissance a priori sur les objets, et est laborieuse lorsque les formes géométriques sont complexes. La simplicité des

modèles limite par conséquent la capture des spécificités des objets, ce qui devient pénalisant lorsque le nombre de classe augmente. Pour cela, l'apparence des objets constitue une source d'information que plusieurs travaux ont tenté de mettre à profit.

Apprentissage des variations d'apparence. L'approche sans doute la plus intuitive consiste à apprendre les variations d'apparence générées par les changements de pose des objets au sein d'un unique classifieur. Au cours de la reconnaissance, cet apprentissage permet de classifier une nouvelle observation quelle que soit sa pose. L'apprentissage fait intervenir une collection d'images et fait partie des approches 2,5D. Un modèle actif d'apparence, proposé par [Cootes et al., 2002], permet d'intégrer de manière continue les variations de silhouette et d'apparence de visage sur un intervalle de 180 degrés à partir de 5 images d'apprentissage, ce qui permet une reconnaissance quelle que soit l'apparence dans cet intervalle. Les descripteurs "étendus" de [Bart et al., 2004] permettent un niveau d'invariance similaire. Pour prendre en compte la variation d'apparence sur l'ensemble de l'azimut, un apprentissage supervisé par SVMs sur l'ensemble des images de l'objet a été proposé par [Roobaert et Van Hulle, 1999] à partir d'un descripteur basé sur l'intensité des pixels. Une approche similaire est adoptée par [LeCun et al., 2004]. Cette dernière approche est simple à mettre en œuvre car contrairement à l'approche basée modèle, l'apprentissage ne nécessite pas de connaissance a priori aussi élevée sur les modèles.

Variétés géométriques d'apparence. Les variétés géométriques d'apparence sont définies par une courbe unidimensionnelle dans l'espace de représentation. Cet espace propre de dimension inférieure au vecteur de représentation initial des images est obtenu par ACP à l'aide de l'ensemble des images et permet une invariance aux autres sources de variations intra-classe. La classe et la pose associées à une nouvelle observation sont estimées à partir de la mesure de la distance à la variété de chaque objet. [Turk et Pentland, 1991] utilisent ce principe pour une reconnaissance de visages invariante sur de larges intervalles de CPDV. Une reconnaissance 3D par cette approche est due aux travaux de [Nayar et al., 1996]. Les performances sont similaires à celles de [Roobaert et Van Hulle, 1999]. Plusieurs travaux en reconnaissance active sont basés sur cette représentation [Borotschnig et al., 1998; Winkeler et al., 1999; Paletta et Pinz, 2000; Sipe et Casasent, 2002; Roy et Kulkarni, 2004]. Cependant, dans les deux cas, la construction des modèles repose sur une segmentation des objets et une représentation basée sur l'intensité des pixels. La reconnaissance est par conséquent très sensible à la fois à la précision de la segmentation, aux occultations et à la présence d'autres objets dans la scène [LeCun et al., 2004].

Descripteurs mixtes

La combinaison d'une représentation d'apparence et d'une représentation structurelle pour la reconnaissance 3D est une extension naturelle des modèles de constellation. Pour faire face aux variations d'apparence engendrées par les grandes variations de CPDV, un apprentissage de caractéristiques locales semble nécessaire pour permettre une bonne généralisation [Li et al., 2008]. Ces caractéristiques, bien qu'invariantes pour de petites variations de CPDV (généralement assimilées localement à des transformations affines) ne peuvent cependant pas décrire l'objet pour l'ensemble des CPDV [Moreels et Perona, 2007]. L'avantage des modèles de constellations résidant dans un nombre faible de descripteurs locaux, cela revient à considérer des intervalles de pose de l'objet décrits par un ensemble restreint de descripteurs invariants dans ces intervalles. Le choix de ces intervalles est étroitement lié à la notion d'aspect de l'objet [Koenderink et Doorn, 1979; Bowyer et Dyer, 1990]. Dans sa définition géométrique initiale, l'aspect d'un objet représente l'ensemble des CPDV pour lesquelles la topologie visible de l'objet est constante. Un changement de topologie, appelé aussi événement visuel, engendre une transition d'aspect. Il peut être l'apparition ou la disparition d'une face de l'objet. L'ensemble des aspects et de leurs

transitions est appelé le graphe d'aspect de l'objet. Plusieurs travaux mettent en œuvre cette modélisation pour la reconnaissance, notamment à partir de primitives géométriques [Dickinson et al., 1992; Herbin, 1998] ou par combinaison de zones localement planes décrites par leur apparence [Huang et al., 1997] (se référer également à [Forsyth et Ponce, 2002] pour une revue des performances obtenues par cette approche). Cependant, selon cette définition, le graphe d'aspect d'un objet quelconque peut être extrêmement complexe [Faugeras et al., 1992; Petitjean, 1996]. De nombreuses techniques d'estimation de graphe d'aspect sont basées sur des simplifications de cette notion, adaptées à la tâche de reconnaissance sous-jacente, conduisant à des graphes approchés. [Schmid et al., 1996] proposent une représentation par images d'aspect. Les caractéristiques de l'objet prédites en théorie par les graphes d'aspect sont souvent difficiles à détecter sur les images réelles du fait de leur complexité. Un nombre très réduit d'images d'apprentissage est utilisé pour une modélisation complète à partir de caractéristiques réelles extraites de celles-ci. Cependant, cette technique nécessite un modèle CAO des objets pour permettre la reconnaissance sous l'ensemble des poses de l'objet. Une recherche d'aspects à partir de l'invariance de l'apparence est mise en œuvre par [Seibert et Waxman, 1992] à travers des réseaux d'aspects. Les nœuds du réseau sont obtenus par agglomération des vecteurs descripteurs dans l'espace de représentation. Le seuil de distance utilisé dans l'agglomération contrôle la complexité du réseau, et est choisi de manière à minimiser l'erreur de reconnaissance.

La notion d'aspect devient de plus en plus implicite à travers le modèle de [Thomas et al., 2006], basé sur une généralisation de la représentation par ISM⁴ [Leibe et al., 2004]. Les descripteurs locaux sont définis à partir des points d'intérêt de l'objet et les différentes vues sont reliées entre elles par le biais de transformations affines permettant, lors de la reconnaissance, de faire voter les zones des vues voisines de la pose observée. Des relations géométriques par transformations affines sont également mises en œuvre par [Lazebnik et al., 2004; Rothganger et al., 2006]. [Savarese et Fei-Fei, 2007] adoptent une approche similaire plus générique basée sur la géométrie épipolaire [Hartley, 2008] et une représentation par un dictionnaire de mots visuels [Csurka et al., 2004]. Des vues canoniques des objets sont extraites automatiquement à partir de l'apparence. Les descripteurs au sein d'une vue canonique sont reliés entre eux par des translations tandis que des homographies relient les vues canoniques entre elles. Les performances de ces modèles d'objets génériques sont encore améliorées par les modèles latents d'aspects discriminatifs de [Farhadi et al., 2009], capables de définir des aspects communs à l'ensemble des classes et d'associer une description optimale au sein de chacun de ces aspects pour améliorer la reconnaissance.

La géométrie épipolaire est également utilisée dans un cadre de synthèse d'images à partir d'un morphisme de vues adjacentes [Khan et al., 2007; Savarese et Fei-Fei, 2008; Xiao et Shah, 2004], permettant de compléter artificiellement les vues manquantes du modèle et autorisant une reconnaissance quelles que soient les CPDV.

1.3.4 Réduction de la dimension et sélection de caractéristiques

La représentation des images impliquée dans le processus de reconnaissance génère des vecteurs descripteurs souvent de grande dimension. L'implémentation du descripteur SIFT par [Lowe, 2004] conduit à un vecteur de dimension 128, la pyramide spatiale de représentation impliquée dans [Lazebnik et al., 2006] peut conduire à un vecteur de plus de 30000 dimensions, et la description par ondelettes de Haar génère plusieurs centaines de milliers de caractéristiques différentes parmi lesquelles seules quelques dizaines sont effectivement utiles pour la tâche sous-jacente. Face à ces tailles importantes, des techniques de réduction de dimension sont nécessaires. Les bénéfices recherchés sont multiples. Une dimension réduite permet un apprentissage et une classification plus rapides, un espace

4. Implicit Shape Model.

mémoire moindre, et constitue un remède au fléau de la dimension (cf. section 1.2.3). Les techniques de description abordées précédemment (sections 1.3.1 et 1.3.2) contiennent pour la plupart une étape de réduction préliminaire de la dimension. L'approche par sac de mots [Csurka et al., 2004] conduit, par une agglomération d'un descripteur dense, à un vecteur d'occurrence de M agglomérats, où M est très inférieur à la dimension initiale de l'image. La sélection de régions locales de description les plus utiles dans les modèles de constellation permet également une réduction préalable de la dimension [Torralba et al., 2007; Ullman et al., 2002; Levi et Weiss, 2004]. Cependant, une réduction ultérieure est généralement nécessaire. Les différentes techniques sont abordées ci-après dans le cadre de la classification supervisée.

Le succès de la réduction de la dimension est étroitement lié à la définition du critère de réduction associé. Un sous-espace optimal de projection des données doit satisfaire les notions de pertinence et d'utilité (i.e. de non redondance de l'information) [Blum et Langley, 1997]. Deux méthodes de réduction peuvent être distinguées : l'approche par "filter" et par "wrapper" [Guyon et Elisseeff, 2003].

L'approche "filter" consiste à réduire la dimension par un critère d'optimalité indirecte généralement plus facile à mettre en œuvre. Une méthode très populaire est l'analyse en composantes principales (ACP) [Jolliffe, 2002], permettant une projection des données sur une base orthogonale de manière à maximiser la variance des données. Bien que ce critère soit a priori indépendant de la tâche de classification sous-jacente, la restriction aux M premières composantes est consistante avec la minimisation de l'erreur de prédiction dans le cas de modèles gaussiens [Moghaddam et Pentland, 1997]. L'ACP est très utilisée, notamment dans les approches par variétés géométriques d'apparence (cf. section 1.3.2), ou dans la réduction de la dimension de descripteurs d'apparence locaux [Ke et Sukthankar, 2004]. Une deuxième méthode "filter" populaire, due à [Fisher, 1936], est l'analyse discriminante, avec en particulier sa version linéaire (ADL). Contrairement à l'ACP, l'ADL est utilisée dans un cadre supervisé. L'objectif de l'ADL et de ses variantes [Tang et al., 2005] consiste à maximiser la variance inter-classes tout en minimisant la variance intra-classe. Cet objectif tend à minimiser indirectement l'erreur de classification, par exemple en reconnaissance de visages [Liu et Wechsler, 2002]. Les techniques de réduction par ACP et ADL peuvent être réalisées en combinaison avec les méthodes à noyau. En remplaçant le produit scalaire initial par une mesure de distance non linéaire, l'optimalité est susceptible d'être améliorée [Muller et al., 2001]. Cependant, le choix du noyau nécessite souvent des connaissances a priori sur les données.

Au lieu de transformer l'ensemble des données par projection, la réduction de la dimension peut être réalisée par la sélection d'un sous-ensemble de caractéristiques. Une revue intéressante des principales techniques de sélection et des méthodes associées est disponible dans [Zongker et Jain, 1996; Guyon et Elisseeff, 2003; van der Maaten et al., 2009]. Une approche de sélection par "filter" très répandue est basée sur la notion d'information entre les caractéristiques et les classes. Elle peut être mesurée par l'information mutuelle [Torkkola, 2003; Liu et al., 2009] (pour lesquelles des méthodes efficaces d'estimation ont été proposées [Kraskov et al., 2004; Fleuret, 2004]) ou par des méthodes alternatives [Jung et al., 2010].

Contrairement à l'approche "filter", l'approche "wrapper" utilise directement le résultat de la tâche sous-jacente (i.e. de la classification) comme critère associé à la réduction de la dimension. Elle offre en particulier un moyen efficace de sélection de caractéristiques. L'erreur de classification par l'algorithme des K -ppv est adopté par [Villegas et Paredes, 2010]. [Hardin et al., 2004] utilise un SVM linéaire, tandis que [Strobl et al., 2008; Genuer et al., 2010] basent la sélection sur une mesure d'importance des variables qui est extraite du classifieur par forêts aléatoires. Une autre méthode "wrapper" très utilisée est réalisée à partir d'un classifieur par boosting. Elle consiste à sélectionner les caractéristiques par le biais de classifieurs faibles très simples à calculer, puis à combiner l'ensemble des couples

classifieur-caractéristique pour obtenir à la fois le classifieur final et le sous ensemble de caractéristiques utiles. La sélection peut être réalisée hors ligne [Viola et Jones, 2001; Zhang et al., 2008] ou mise à jour au cours de la reconnaissance pour s'adapter aux variations des données [Liu et al., 2007].

Plus récemment, l'utilisation d'algorithmes évolutionnistes pour résoudre le problème d'optimisation sous-jacent à la sélection de caractéristiques permettent d'améliorer l'efficacité de l'extraction. Ils sont mis en œuvre dans les approches "filter" [Sarojini et Thangavel, 2010] et "wrapper" [Yusta, 2009].

Notons enfin qu'une dernière méthode de réduction de la dimension consiste en une sélection conjointe à l'apprentissage du classifieur, en l'intégrant dans le problème d'optimisation sous-jacent. Cette technique est notamment mise en œuvre avec la classification par SVM [Nguyen et de la Torre, 2010].

CONCLUSION DU CHAPITRE

L'étude bibliographique réalisée dans ce chapitre, bien que non exhaustive, a montré que l'intérêt pour la classification automatique d'images est apparu dès l'émergence des moyens informatiques et est aujourd'hui encore majeur. Le nombre de stratégies de descriptions et de classification est considérable et continue de croître. Cette vision des travaux existants permettra, dans les chapitres suivants, de guider le choix d'une représentation et d'une modélisation adéquate du problème de reconnaissance active considéré dans cette thèse.

Ce chapitre a également permis de constater que le choix d'une description des images était essentiel à la classification, car le descripteur permet de réduire la complexité des espaces de représentation et de lui dépend la fiabilité de l'inférence. La variété des description permet une grande agilité dans la prise d'information dans l'image. La reconnaissance active repose également sur l'agilité de l'agent visuel dans la prise d'information. Alors que dans ce chapitre ce choix est réalisé hors ligne par l'utilisateur (ce qui est souvent le cas pour les problèmes de classification d'image), le chapitre suivant s'attache à formaliser l'agilité dans la prise d'information dans la scène pour une sélection en ligne des informations utiles, ce qui caractérise un système de reconnaissance active.

FORMALISME POUR UNE RECONNAISSANCE ACTIVE

2

Ce chapitre a pour but de proposer un formalisme mathématique pour une reconnaissance active. En s'appuyant sur le cadre bayésien défini au chapitre précédent pour la classification supervisée, ainsi que sur la théorie des systèmes inverses, deux spécificités sont établies. D'une part, un schéma d'inférence probabiliste permet d'estimer la classe de l'objet à partir de l'ensemble des sources d'information disponibles sur la scène (section 2.2). D'autre part, deux caractéristiques essentielles à la vision active sont considérées. La première est un schéma d'intégration séquentielle de l'information, et la deuxième est un terme de planification de la prochaine information à acquérir qui est explicitement introduit dans ce schéma (section 2.3). Une présentation des principaux formalismes rencontrés, avec leurs avantages et leurs inconvénients, est également réalisée et permet de situer l'approche adoptée parmi celles existantes. L'algorithme général de reconnaissance active est ensuite établi, et les critères de performance attendus d'une stratégie de planification sont définis, en prévision des chapitres suivants.

PLAN DU CHAPITRE

Ce chapitre est organisé de la manière suivante : après une justification de sa mise en œuvre (section 2.1), le formalisme mathématique et les hypothèses sous-jacentes pour une reconnaissance sont introduits à la section 2.2. L'intégration d'une nouvelle observation et la formulation explicite de la stratégie de planification des modalités d'acquisition sont établies à la section 2.3. Les principaux travaux mettant en œuvre un cadre bayésien similaire pour la reconnaissance d'objet sont rappelés (section 2.2.2), ainsi qu'une revue de plusieurs autres techniques de fusion de l'information (section 2.3.1).

2.1 INTRODUCTION

La majorité des applications de reconnaissance automatique d'objets est statique. La classe (ou label) est inférée à partir d'une unique observation. Dans le cadre de la classification supervisée, cette inférence est réalisée au moyen d'un classifieur préalablement entraîné à l'aide de données d'apprentissage annotées. Cette approche a connu un essor important avec l'avènement des moyens informatiques et le développement des supports numériques de stockage des images. Les méthodes les plus récentes de description des images et de classification sont capables d'atteindre des taux de reconnaissance très élevés, généralement supérieurs à 90% sur les bases de données usuelles ([Amores et al., 2007; Epshtein et Ullman, 2006; Mutch et Lowe, 2006; Csurka et al., 2004; Moosmann et al., 2006]). L'approche statique est cependant limitée pour la reconnaissance d'objets 3D. Bien que les récentes techniques de description offrent à la fois une capacité de discrimination et une robustesse accrue aux variations intra-classe (se référer à la section 1.3.2), le changement d'apparence induit par le changement des modalités d'acquisition (en particulier des CPDV) est souvent important. C'est pourquoi l'apprentissage est généralement basé sur la connaissance a priori de la pose des objets. Plusieurs approches ont néanmoins été proposées pour représenter les objets 3D de manière invariante avec les CPDV (se référer à la section 1.3.3). Mais ces méthodes ne permettent pas de généraliser à la 3D le niveau de performance de classification 2D [Savarese et Fei-Fei, 2007]. Une autre stratégie consiste à dupliquer les classifieurs, chacun d'entre eux étant spécialisé pour une pose particulière de l'objet. La classification est alors réalisée en combinant la réponse de l'ensemble des classifieurs [Macrini et al., 2002; Ozcanli et al., 2006]. Mais cette stratégie, en plus de générer un apprentissage fastidieux, reste statique : elle ne permet pas de résoudre les ambiguïtés, dues aux similarités d'apparence entre les objets, qui sont inhérentes à la reconnaissance. Selon les modalités d'acquisition choisies, ces similarités peuvent disparaître entre certains objets et apparaître entre d'autres.

La reconnaissance active permet de dépasser cette limitation en basant l'inférence sur une séquence d'observations dont les modalités d'acquisition sont choisies délibérément. Dans ce but, un formalisme de reconnaissance multi-observations est établi. Il s'appuie sur les travaux de [Tarantola, 1987] en théorie des systèmes inverses (section 2.2). Il s'en distingue cependant par l'ajout de deux spécificités liées à la reconnaissance active (section 2.3).

La première d'entre elles est de permettre de retarder la prise de décision en accumulant l'information à l'aide d'un système d'inférence séquentiel. La problématique liée à cette prise de décision séquentielle est de fusionner correctement les informations collectées pour renforcer la confiance en l'inférence. La quantité d'information sur l'objet observé ayant une influence directe sur la confiance de la classification, la manière d'accumuler l'information influence la prise de décision. Cette première spécificité est abordée par l'utilisation d'un cadre probabiliste pour la reconnaissance.

La deuxième spécificité du formalisme consiste en la prise en compte de l'aspect actif de la reconnaissance. Une reconnaissance multi-observations passive (c'est-à-dire sans stratégie de planification) ne permet pas de résoudre systématiquement les ambiguïtés

entre les classes. Une sélection explicite des modalités d'acquisition de chaque observation est intégrée au formalisme. Elle traduit la possibilité d'établir une stratégie de planification.

2.2 CADRE PROBABILISTE POUR LA RECONNAISSANCE

Dans cette section, un cadre bayésien pour une reconnaissance multi-observations est présenté. Les notations introduites dans ce formalisme seront également utilisées dans les chapitres suivants.

2.2.1 Reconnaissance statistique : approche bayésienne

Soit $\Omega = \{1, \dots, \mathcal{K}\}$ un ensemble de \mathcal{K} classes ou labels. La classe d'un objet observé est inférée sur Ω à partir de mesures. Dans le cadre de la reconnaissance active, chaque observation est associée à une variable $v \in \mathcal{V}$ définissant de manière générique les modalités d'acquisition (CPDV, type d'information, focale...). Une mesure est donc définie par une paire observation-modalité notée (x, v) qui sont des variables aléatoires sur $\mathcal{X} \times \mathcal{V}$. L'inférence consiste à comparer la mesure aux modèles constituant la base de données. Ces modèles sont représentés par un ensemble de paramètres $\{\theta_1, \dots, \theta_{\mathcal{K}}\}$ tels que $\theta_k \in \Theta$. \mathcal{X} est l'espace des observations, \mathcal{V} l'espace des modalités, Θ l'espace des modèles, et Ω l'espace de décision. Le cadre probabiliste permet la prise en compte de l'incertitude. Pour cela, les variables aléatoires ω et θ sont définies respectivement sur Ω et Θ .

Un cadre statique est tout d'abord considéré. Le problème inverse, inférer la classe à partir des mesures, consiste à obtenir la distribution de probabilité a posteriori sur l'ensemble des classes conditionnée à un couple observation-modalité. Cette probabilité est notée $P(\omega | x, v)$. Son calcul fait intervenir des distributions de probabilité pour modéliser l'incertitude sur les différentes sources d'information ainsi que sur l'espace des modèles. Ces distributions sont décrites ci-après.

Information a priori

Une information a priori est définie par toute connaissance antérieure aux observations de l'objet et pouvant influencer la prise de décision. Elle est représentée par la probabilité $P(\omega)$ ($\omega \in \Omega$). Par exemple, le contexte de l'objet (lieu, entourage, période) peut être mis à profit pour favoriser la reconnaissance en supposant qu'en cette période ou en ce lieu, la classe $\omega = k$ est très improbable et que sa probabilité a priori peut être diminuée. La question du choix d'une distribution a priori particulière dépasse le cadre de cette étude. En l'absence d'information spécifique, une loi uniforme sera considérée pour $P(\omega)$ dans la suite.

Mesure

La mesure constitue la source d'information principale du problème de décision. Elle peut cependant être entachée de bruit. L'incertitude qui en découle est représentée par la densité conditionnelle ou vraisemblance des données $P(x, v | \theta)$.

Modèles

Les modèles d'objet paramétriques constituent une troisième source d'incertitude pour la reconnaissance. Les paramètres $\{\theta_1, \dots, \theta_{\mathcal{K}}\}$ doivent tenir compte de la variabilité intra-classe des observations. Cette variabilité est représentée par la densité conditionnelle $P(\theta | \omega)$, $\omega \in \Omega$, qui décrit le comportement des paramètres pour chacune des classes. L'approche bayésienne pour la reconnaissance a pour objectif de combiner deux informations : la densité (inconnue) $P(\omega, \theta)$ qui gouverne le comportement joint du modèle et de

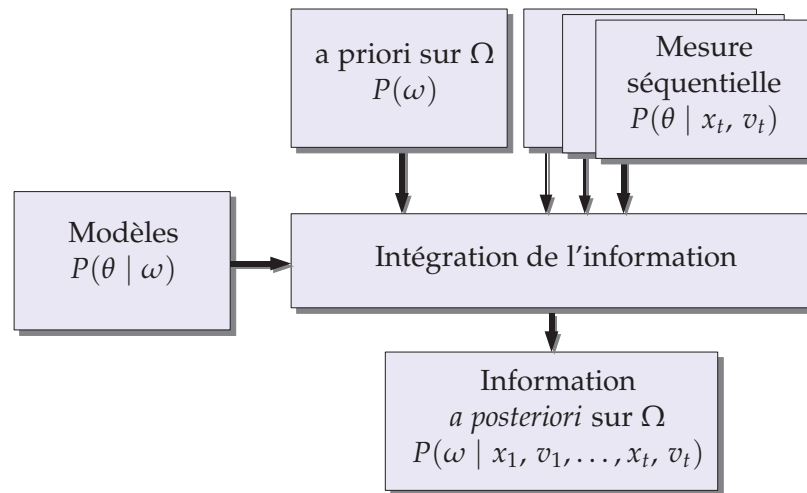


FIGURE 2.1 – Éléments constitutifs de la prise de décision séquentielle.

la classe, et la densité (inconnue également) $P(\theta, x)$ qui gouverne le comportement joint du modèle et de l'observation. La règle de Bayes conduit à l'égalité

$$\begin{aligned}
 P(\omega | x, v) &= \frac{P(x, v | \omega)P(\omega)}{P(x, v)} \\
 &\propto P(\omega)P(x, v | \omega)
 \end{aligned} \tag{2.1}$$

La densité $P(x, v | \omega)$, que nous appellerons également vraisemblance d'une mesure conditionnée à la classe, peut être reformulée en marginalisant la variable aléatoire θ :

$$P(x, v | \omega) = \int_{\Theta} P(x, v | \theta)P(\theta | \omega)d\theta \tag{2.2}$$

Nous en déduisons :

$$P(\omega | x, v) \propto P(\omega) \int_{\Theta} P(x, v | \theta)P(\theta | \omega)d\theta \tag{2.3}$$

L'équation 2.3 met en évidence le lien créé entre l'information dite de "bas niveau" (la mesure) et l'information de "haut niveau" (son interprétation pour la classification). Ce lien est assuré par les modèles.

2.2.2 Autres travaux sur la reconnaissance statistique bayésienne

L'approche bayésienne est mise en œuvre dans de nombreux travaux. Le cadre probabiliste associé permet un découpage et une modélisation spécifique de chaque source d'information ou d'incertitude. [Moghaddam et Pentland, 1997] utilisent cette approche combinée avec une modélisation de vraisemblance gaussienne dans le cadre de la détection de visages. Les modèles de constellation (cf. Section 1.3.1), qui combinent une modélisation d'apparence et géométrique, font également intervenir le cadre bayésien [Fergus et al., 2003; Felzenszwalb et Huttenlocher, 2005; Amit et Trouvé, 2007; Sun et al., 2009].

2.3 INTÉGRATION SÉQUENTIELLE DE L'INFORMATION

Cette section présente le schéma général d'intégration des observations qui, combiné avec le cadre bayésien de la section précédente, est au cœur du processus de reconnaissance active. L'analogie de ce schéma avec d'autres travaux est analysée. Il n'est cependant pas unique. La section 2.3.1 donne une revue des principales autres approches.

2.3.1 Intégration bayésienne

L'équation (2.3) permet d'inférer la classe ω de l'objet à partir d'une mesure x . Cette inférence a été considérée statique. Ici, le cadre bayésien est utilisé pour définir une inférence dynamique, c'est-à-dire actualisée au fur et à mesure de l'acquisition des observations.

Notations et hypothèses

Dans un contexte séquentiel temporel, chaque observation est caractérisée par un instant d'acquisition unique $t \in \mathbb{N}$. Elle est notée x_t . Une séquence de t paires observations-modalités est définie par

$$\mathbf{X}_t = \{x_1, \dots, x_t\} \quad (2.4)$$

$$\mathbf{V}_t = \{v_1, \dots, v_t\} \quad (2.5)$$

Au pas de temps t , le résultat du classifieur est exprimé par la probabilité a posteriori $P(\omega | \mathbf{X}_t, \mathbf{V}_t)$. Contrairement à l'équation (2.3), la distribution sur Ω est maintenant conditionnée à l'ensemble des observations acquises qui constituent l'information accumulée par le système.

Étant donnée la séquence $(\mathbf{X}_t, \mathbf{V}_t)$, l'intégration d'une nouvelle mesure (x_{t+1}, v_{t+1}) est effectuée à partir de la vraisemblance (2.2) de la manière suivante

$$\begin{aligned} P(\mathbf{X}_t, \mathbf{V}_t, x_{t+1}, v_{t+1} | \omega) &= P(x_{t+1}, v_{t+1} | \mathbf{X}_t, \mathbf{V}_t, \omega) P(\mathbf{X}_t, \mathbf{V}_t | \omega) \\ &= P(x_{t+1} | v_{t+1}, \mathbf{X}_t, \mathbf{V}_t, \omega) \\ &\quad \times P(v_{t+1} | \mathbf{X}_t, \mathbf{V}_t, \omega) \\ &\quad \times P(\mathbf{X}_t, \mathbf{V}_t | \omega) \end{aligned} \quad (2.6)$$

Cette équation fait apparaître un schéma d'intégration récursif où la vraisemblance actuelle dépend de la vraisemblance précédente. L'information est capitalisée jusqu'à ce qu'une confiance acceptable en la décision soit atteinte.

Le calcul de l'intégration est basé sur deux hypothèses d'indépendance entre les données. Elles sont définies par :

$$P(x_t | x_{t-1}) = P(x_t) \quad (2.7)$$

$$P(x_t | v_{t-1}) = P(x_t) \quad (2.8)$$

Les hypothèses (2.7) et (2.8) conduisent à

$$P(x_{t+1} | v_{t+1}, \mathbf{X}_t, \mathbf{V}_t, \omega) = P(x_{t+1} | v_{t+1}, \omega) \quad (2.9)$$

ce qui, reporté dans l'équation (2.6), donne le schéma final d'intégration bayésien

$$P(\mathbf{X}_t, \mathbf{V}_t, x_{t+1}, v_{t+1} | \omega) = P(x_{t+1} | v_{t+1}, \omega) P(v_{t+1} | \mathbf{X}_t, \mathbf{V}_t, \omega) \times P(\mathbf{X}_t, \mathbf{V}_t | \omega) \quad (2.10)$$

La probabilité a posteriori, conditionnée à la séquence d'observations, est obtenue par inversion bayésienne

$$P(\omega | \mathbf{X}_{t+1}, \mathbf{V}_{t+1}) = \frac{P(\mathbf{X}_{t+1}, \mathbf{V}_{t+1} | \omega) P(\omega)}{\sum_{\omega \in \Omega} P(\mathbf{X}_{t+1}, \mathbf{V}_{t+1} | \omega)} \quad (2.11)$$

et le classifieur est donné par :

$$\hat{f}(\mathbf{X}_{t+1}, \mathbf{V}_{t+1}) = \underset{\omega \in \Omega}{\operatorname{argmax}} P(\omega | \mathbf{X}_{t+1}, \mathbf{V}_{t+1}) \quad (2.12)$$

Analyse

Une première remarque sur l'équation (2.11) est liée à l'analogie avec les processus de décision markovien (PDM) [Sutton et Barto, 1998], dans lesquels le passé est résumé par l'état du système et où la transition vers l'état futur ne dépend que de l'état actuel. Le cadre des MDP est utilisé au chapitre 5. Dans ce cadre, le choix des prochaines modalités d'acquisition est équivalent au choix d'une action sur \mathcal{V} . Dans les autres chapitres, nous adopterons cependant un formalisme plus proche de la reconnaissance statistique. L'état du système n'apparaît pas de manière explicite, il est néanmoins contenu dans la vraisemblance $P(\mathbf{X}_t, \mathbf{V}_t \mid \omega)$.

La fusion bayésienne de l'information qui a été définie est utilisée dans plusieurs travaux en reconnaissance active, dont [Borotschnig et al., 1998; Paletta et al., 2000]. Cependant, dans ces travaux, l'inférence fait intervenir une distribution jointe observation-modalité. Ici, elles sont considérées comme séparables.

Le terme $P(x_{t+1} \mid v_{t+1}, \omega)$ définit la vraisemblance de l'observation x_{t+1} étant données les modalités d'acquisition et la classe. Il est issu du classifieur. Celui-ci est proche de la vraisemblance (2.3), mais ici l'observation est conditionnée aux modalités. Cela signifie que les modalités doivent être connues a priori à l'estimation de cette vraisemblance. Cette connaissance est établie par

$$P(v_{t+1} \mid \mathbf{X}_t, \mathbf{V}_t, \omega) \quad (2.13)$$

qui représente une densité de probabilité sur les prochaines modalités. Alors que la vraisemblance (2.3) définit de manière statique l'incertitude sur le couple observation-modalité pour chaque modèle, la vraisemblance conditionnelle (2.13) permet une recherche dynamique de l'information dans laquelle la connaissance actuelle est utilisée activement. Cette distribution modélise la politique de planification qui est au cœur de la reconnaissance active. De manière équivalente, elle permet de choisir quelle nouvelle information devrait être intégrée à la connaissance actuelle. Cela conduit aux résultats principaux présentés dans cette thèse : en définissant cette distribution de manière à favoriser le choix des modalités les plus informatives, la probabilité a posteriori (2.11) devrait converger plus rapidement vers la vraie classe de l'objet par rapport à toute autre loi de sélection (qui est considérée comme une reconnaissance multi-observations passive).

2.3.2 Autres approches pour l'intégration

Plusieurs autres schémas d'accumulation de l'information ont été proposés dans le cadre de la reconnaissance active. Les principaux d'entre eux sont abordés dans cette section.

[Arbel, 2000] considère, à chaque pas de temps t , la probabilité a posteriori $P(\omega \mid x_t, v_t)$ comme information a priori au pas de temps $t + 1$. Plus précisément, partant de (2.2),

$$P(\omega \mid x_t, v_t, x_{t+1}, v_{t+1}) \propto P(\omega \mid x_t, v_t) \int_{\Theta} P(x_{t+1}, v_{t+1} \mid \theta) P(\theta \mid \omega) d\theta \quad (2.14)$$

Ce chaînage est également mis en œuvre par [Denzler et Brown, 2002; Arbel et Ferrie, 1999]. Ce schéma d'intégration a cependant plusieurs inconvénients. D'une part, contrairement au schéma adopté, il ne repose que sur une considération intuitive (la probabilité a posteriori actuelle devient la probabilité a priori future). D'autre part, l'information est conservée et propagée à travers le terme a priori $P(\omega \mid x_t, v_t)$, ce qui rend ce schéma beaucoup plus implicite. Le schéma adopté dans cette thèse offre l'avantage de conserver le terme *a priori* exclusivement pour l'information disponible antérieurement à toute observation. La connaissance actuelle est quant à elle explicitement définie par la distribution (2.11) qui est fonction de l'ensemble des mesures $(\mathbf{X}_t, \mathbf{V}_t)$.

[Deinzer et al., 2001] définit également l'état du système par le biais de la probabilité a posteriori (2.11). Une observation est interprétée comme transition d'un état de connaissance à un autre. Pour résoudre le problème de propagation de densité dans un cas non

gaussien, une technique de filtrage particulière a été mise en œuvre et résolue par l'algorithme CONDENSATION [Isard et Blake, 1998].

Une alternative à l'approche probabiliste pour la fusion repose sur la théorie des fonctions de croyance ou théorie de Dempster-Shafer [Shafer, 1976]. L'objectif poursuivi est de déterminer la manière optimale de fusionner la compétence d'un ensemble de classifieurs experts. L'optimalité est définie au regard de l'efficacité mesurée a posteriori, c'est-à-dire la performance de reconnaissance. Cela conduit aux approches possibiliste et crédibiliste. De nombreux opérateurs de fusion en découlent. Une revue comparative de ces opérateurs est proposée par [Bloch, 1996]. Bien que la fusion de données soit avant tout guidée par l'objectif à atteindre au détriment de la rigueur propre au cadre probabiliste, [Kittler et al., 1998] a proposé une base théorique de plusieurs schémas de fusion dans le contexte de la reconnaissance de caractères et une analyse de leur sensibilité aux erreurs d'estimation. De ce point de vue, le schéma bayésien adopté dans cette thèse peut être considéré comme le cas particulier de la règle du produit. Une comparaison entre les approches probabiliste, possibiliste (règle du "min") et par fonction de croyance est proposée par [Borotschnig et al., 1999] pour la reconnaissance d'objets. Dans [Xu et al., 1992] les croyances sont utilisées pour combiner plusieurs classifieurs dans le cadre de la reconnaissance de caractères. Le schéma bayésien, conjonctif au sens de [Bloch, 1996] est susceptible d'être moins robuste aux données aberrantes qui pénalisent fortement la décision finale. Cependant, l'initialisation des schémas dits alternatifs repose systématiquement sur le cadre probabiliste, qui est omniprésent. De plus, l'utilisation des fonctions de croyance, qui associent des masses aux 2^k sous ensembles possibles de classes, se trouve fortement pénalisée lorsque le nombre de classes est élevé, comme constaté par [Borotschnig et al., 1999; Xu et al., 1992].

Une dernière catégorie de fusion est basée sur la recherche d'une combinaison linéaire optimale des classifieurs. Dans le cas de classifieurs continus (telles que les probabilités a posteriori), [Ho et al., 1994] réalise la combinaison via une fonction de régression logistique. Les coefficients de régression sont obtenus par maximisation de la vraisemblance sur les données d'apprentissage ou par moindres carrés. [Xu et al., 1992] proposent une méthode de combinaison par vote majoritaire ainsi qu'une estimation des coefficients par le biais des matrices de confusion de chaque classifieur. La combinaison peut également être réalisée de manière à mettre à profit l'expertise locale de chaque classifieur dans l'élaboration du classifieur final, comme réalisé par le boosting [Schapire et al., 1998]. Cependant, ces dernières approches sont basées sur la connaissance simultanée de l'ensemble des réponses des classifieurs impliqués dans l'inférence. Cette nécessité est difficilement compatible avec l'aspect séquentiel de la reconnaissance active.

2.4 RECONNAISSANCE ACTIVE

Le cadre formel établi à la section précédente est ici intégré dans une procédure globale de reconnaissance active. Celle-ci est schématisée à la figure 2.2. Ce schéma tient compte d'une perturbation au niveau des actionneurs. Cela se traduit par une possible différence entre les modalités d'acquisition planifiées v_{t+1} et les modalités v_t réellement atteintes. Une modélisation de cette incertitude est abordée à la section 3.2.1. Un autre élément important dans ce schéma est le critère d'arrêt de la reconnaissance active, qui est abordé ci-après.

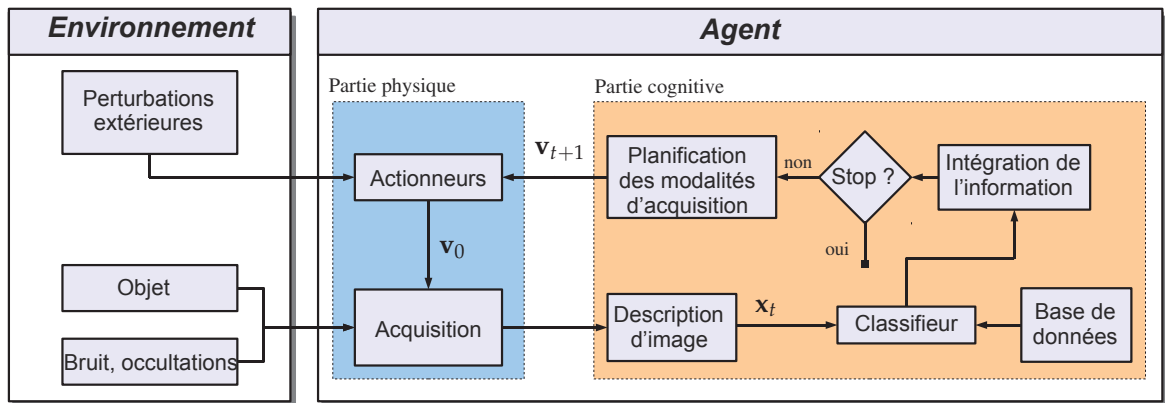


FIGURE 2.2 – Boucle fermée de reconnaissance active entre le système de décision (l'agent) et son environnement.

2.4.1 Critère d'arrêt

Le critère d'arrêt de la reconnaissance active doit refléter le souhait de l'utilisateur. indépendamment de l'aspect actif (dont les critères de performance seront abordés à la section 2.4.3), l'objectif premier est de reconnaître avec une confiance acceptable. La notion d'acceptable est subjective. Elle varie selon la tâche à réaliser et l'utilisateur. Plusieurs stratégies existent pour mesurer cette confiance. Une mesure d'ambiguïté de la reconnaissance est basée sur l'entropie de la distribution a posteriori (2.11). Nous verrons au chapitre 4 que son utilisation est également possible pour la planification des CPDV. L'entropie découle naturellement du cadre probabiliste et conduit à une mesure de la quantité d'information (au sens de Shannon) sur laquelle peut s'appuyer la prise de décision. Elle est notamment utilisée par [Arbel et Ferrie, 1999; Laporte et al., 2004]. Cependant, une telle mesure peut paraître difficile à interpréter et le choix d'un seuil d'information suffisant est délicat et peu intuitif. Une mesure plus directe au regard du cadre probabiliste défini consiste à stopper la reconnaissance et à prendre la décision dès que la probabilité du MAP (2.11) dépasse un seuil P_{\max} . Ce critère, adopté par [Herbin, 1996] est également utilisé ici.

Une contrainte supplémentaire est liée au budget fini d'observations pour la reconnaissance. Ce budget est noté T . Lorsque T observations ont été acquises, la reconnaissance prend fin même si la confiance actuelle n'est pas suffisante. Dans ce cas, il est préférable de ne pas inférer de décision, ce qui conduit à définir la notion de rejet.

2.4.2 Algorithme

La procédure de reconnaissance active mise en œuvre est résumée par l'algorithme 1. Le paramètre d'entrée tol définit une zone d'exclusion autour des modalités déjà visitées de manière à éviter la redondance de l'information.

Algorithme 1: Algorithme mis en œuvre pour la reconnaissance active.

Entrées : modèles : $P(x | v, \omega = k), k = 1, \dots, \mathcal{K}$
politique de planification : $P(v | \mathbf{X}_t, \mathbf{V}_t, \omega)$ (éq. 2.13)
 tol, P_{\max}, T
conditions initiales : x_1, v_1

Sorties : classe de l'objet ω^* ou rejet

```

1  $t \leftarrow 0;$ 
2  $\mathbf{X}_t = \emptyset; \mathbf{V}_t = \emptyset;$ 
3 répéter
4    $P(v | \mathbf{X}_t, \mathbf{V}_t, \omega) = \mathbf{1}_{\{v=v_{t+1}\}};$ 
5    $\mathbf{X}_{t+1} \leftarrow \mathbf{X}_t \cup x_{t+1};$ 
6    $\mathbf{V}_{t+1} \leftarrow \mathbf{V}_t \cup v_{t+1};$ 
7   calculer  $P(\omega | \mathbf{X}_{t+1}, \mathbf{V}_{t+1}), \omega \in \Omega$  (éq. (2.10) et (2.11));
8    $k^* \leftarrow \underset{k}{\operatorname{argmax}} P(\omega = k | \mathbf{X}_{t+1}, \mathbf{V}_{t+1});$ 
9    $t \leftarrow t + 1;$ 
10   $v_{t+1}^* \leftarrow \underset{v_{t+1}}{\operatorname{argmax}} P(v | \mathbf{X}_t, \mathbf{V}_t, \omega), \quad \text{tel que } [v_{t+1} - tol; v_{t+1} + tol] \cap \mathbf{V}_t = \emptyset;$ 
11  aller à  $v_{t+1}^*$ ; observer  $x_{t+1};$ 
12 jusqu'à  $\max_k P(\omega = k | \mathbf{X}_t, \mathbf{V}_t) \geq P_{\max}$  ou  $t = T;$ 
13 si  $P(\omega = k^* | \mathbf{X}_t, \mathbf{V}_t) \geq P_{\max}$  alors
14    $\lfloor$  retourner  $k^*;$ 
15 sinon
16    $\lfloor$  rejet;

```

2.4.3 Critères de performance d'une stratégie de planification

La stratégie de planification des CPDV pour la reconnaissance active est appliquée par le biais de la distribution (2.13). L'optimalité d'une stratégie nécessite la définition d'un ou plusieurs critères reflétant le comportement désiré de l'algorithme. La figure 2.3 illustre l'évolution attendue de la courbe de performance de reconnaissance cumulée (i.e. le taux de bonne reconnaissance est cumulé au fur et à mesure des observations). Dans le cas idéal, la courbe devrait atteindre le taux de performance maximal (performance= 1) dès la première observation. Cela conduit à la définition de trois critères pour traduire ce comportement.

1. *Performance maximale* ($Perf_{\max}$) : elle représente le taux moyen d'interprétations correctes atteint avec un budget d'au plus T observations. Elle correspond à la performance cumulée moyenne à $t = T$. La valeur optimale de ce critère est $Perf_{\max} = 1$ ($0 \leq Perf_{\max} < 1$ dans le cas sous-optimal).
2. *Nombre moyen d'observations* (T_{moy}) : il correspond à la moyenne (en nombre d'observations) de la courbe de performance cumulée. Par cette définition, la valeur optimale de T_{moy} est $\frac{(T+1)}{2}$ (dans le cas sous-optimal, $\frac{(T+1)}{2} < T_{\text{moy}} \leq T$).
3. *Aire sous la courbe de performance cumulée* ($Aire_T$) : synthèse des deux critères précédents, $Aire_T$ doit être la plus élevée possible (i.e. égale à $T - 1$ pour une interprétation correcte dès la première observation).

Ces critères sont complémentaires, et l'optimalité d'une stratégie de planification pour la reconnaissance est équivalente à l'optimalité *simultanée* de $Perf_{\max}$, T_{moy} et $Aire_T$. Cependant, chacun d'entre eux reflète une caractéristique particulière. Dans le cas où le budget d'observations pour la reconnaissance n'est pas limité, $Perf_{\max}$ est le critère le plus important. Dans le cas contraire, une convergence dès les premières observations de la courbe de performance cumulée est recherchée, et T_{moy} devient le

critère d'optimalité prépondérant. Le critère $Aire_T$ est quant à lui une mesure pratique de comparaison entre plusieurs politiques de planification.




FIGURE 2.3 – Illustration des différents critères de performance d'une stratégie de planification.

CONCLUSION DU CHAPITRE

Le cadre mathématique pour une reconnaissance active est désormais établi. Il permet d'inférer la classe à partir d'un ensemble d'observations et d'en intégrer de nouvelles. Cela conduit à une prise de décision de la forme : classifier l'objet ou planifier une nouvelle observation. Cette classification différée est essentielle à la reconnaissance active. Le cadre établi offre également la possibilité de définir explicitement une stratégie de planification, via une distribution de probabilité sur les modalités d'acquisition de la prochaine observation. Plusieurs stratégies seront abordées dans les chapitres suivants. Chacune d'entre elles sera évaluée suivant les critères de performances établis dans ce chapitre. Les modèles d'objets, qui interviennent dans ce formalisme via un ensemble de paramètres, nécessitent encore d'être estimés pour rendre la reconnaissance active opérationnelle. Cette modélisation à l'aide de données d'apprentissage est abordée dans le chapitre suivant.

LE formalisme pour la reconnaissance active introduit dans le chapitre précédent considère une modélisation paramétrique des objets. La connaissance préalable de ces paramètres est nécessaire à la mise en œuvre de la reconnaissance. Les modèles interviennent comme intermédiaires entre les mesures dans la scène (i.e. les observations) et leur interprétation (i.e. la classe). Comme cela a été abordé au chapitre 1, le résultat de l'inférence repose sur l'estimation correcte de ces paramètres, de manière à capturer au mieux la variance intra-classe tout en assurant une variance inter-classes élevée. Dans ce chapitre, une procédure d'estimation est réalisée dans un cadre d'apprentissage supervisé. La modélisation et la reconnaissance de véhicules est en particulier considérée. Une modélisation générative basée sur une description d'apparence globale est adoptée (section 3.2). L'optimalité de l'estimation est évaluée à l'aide de plusieurs critères qui sont comparés. Ce chapitre introduit également le cadre applicatif (section 3.3) qui sera utilisé dans les chapitres suivants pour évaluer les algorithmes proposés.

PLAN DU CHAPITRE

Le chapitre s'articule autour de deux parties. Dans la première, la chaîne globale de traitement est rappelée, et le choix de modélisation pour la reconnaissance de véhicules est abordé (section 3.1). La construction des modèles est présentée à la section 3.2. Elle regroupe à la fois une modélisation de l'incertitude du placement du porteur, qui est spécifique à la reconnaissance active (section 3.2.1), et une modélisation des vraisemblances à l'aide des données d'apprentissage (section 3.2.2). Dans la deuxième partie, la base de données de véhicules et le dispositif expérimental adoptés dans cette thèse sont présentés à la section 3.3. L'optimisation des paramètres des modèles à l'aide des données d'apprentissage est reportée à la section 3.3.3.

3.1 CHOIX D'UNE MODÉLISATION POUR UNE RECONNAISSANCE ACTIVE DE VÉHICULES

Dans cette section, les principales étapes de la chaîne de traitement pour la reconnaissance de véhicules sont rappelées. Les choix de description et de modélisation existants dans la littérature pour la reconnaissance d'objets ont été abordés au chapitre 2. Ici, les principaux travaux spécifiques à la reconnaissance de véhicules sont présentés.

La reconnaissance d'objets, qu'elle soit active ou non, met en œuvre une succession d'étapes dont chacune conditionne la performance finale. Ces étapes font intervenir la modélisation préalable des objets (ou l'apprentissage du classifieur), la description des observations, mais également une étape préliminaire de détection des objets. La chaîne de traitement est illustrée par la figure 3.1. De nombreux travaux ont été réalisés pour rendre performante chacune de ces étapes (le chapitre 1 présente notamment différentes approches de la littérature pour la description et la classification). Dans le cas de la reconnaissance active de véhicules, ces étapes sont abordées ci-après.

3.1.1 Détection

La détection constitue le premier maillon de la chaîne de traitement. Elle consiste à extraire la région d'intérêt de l'image et à présenter l'objet au classifieur de manière similaire aux observations d'apprentissage. Dans la suite, la détection est supposée réalisée. Bien que sa mise en œuvre dépasse le cadre de cette thèse, elle reste néanmoins une étape indispensable et non triviale, c'est pourquoi les principales approches en détection de véhicules sont rappelées.

Deux catégories de détecteurs peuvent être répertoriées. La première est basée sur le mouvement relatif (lorsqu'il existe) de l'objet par rapport à l'observateur, à l'aide d'une mesure de flot optique [Giachetti et al., 1998] ou par un suivi des objets [Koller et al., 1994; Gupte et al., 2002]. Cela permet d'extraire les zones d'intérêt potentiel dans l'image, réduisant ainsi l'espace de recherche. Les candidats extraits n'appartenant pas nécessairement à la catégorie souhaitée (ici les véhicules), une étape de validation est nécessaire et s'appuie sur la deuxième catégorie de détecteurs.

La deuxième catégorie met en œuvre une classification binaire entre l'objet et le reste de l'image (le fond). Le descripteur utilisé pour la détection peut être différent de celui utilisé pour la reconnaissance. Il est cependant confronté aux mêmes contraintes (cf. section 1.3.1). Le choix du descripteur est également lié aux particularités (géométriques et d'apparence) des objets. Dans le cas des véhicules, ceux-ci peuvent en première approche être assimilés à un ensemble d'éléments de surface non texturés et dotés de contours saillants d'orientation spécifique ainsi que d'éléments d'apparence localisés. Un simple rapport d'orientation de gradient est utilisé par [Khammari et al., 2005] pour leur détection. Des ondelettes de Haar suivies d'une classification par boosting est mise en œuvre par [Kluckner et al., 2007].




FIGURE 3.1 – Détection, description, et reconnaissance des véhicules.

[Suna et al., 2004] utilisent un descripteur d'apparence globale et une extraction de caractéristiques par ACP avant d'effectuer la détection à l'aide d'un SVM sur ces caractéristiques. Une méthode statistique est proposée par [Schneiderman et Kanade, 2000]. Une représentation en ondelettes des objets et du fond permet de modéliser l'apparence de chaque classe et d'effectuer la détection à partir d'un rapport de vraisemblance. Des méthodes "basées modèle" sont également mises en œuvre à partir de polyèdres paramétriques appariés aux contours de l'image [Kim et Malik, 2003; Worrall et al., 1994; Koller et al., 1993]. Les variations intra-classe dues aux variations des CPDV conduisent généralement à des détecteurs spécialisés pour une pose particulière [Suna et al., 2004; Khammari et al., 2005; Schneiderman et Kanade, 2000] ou qui sont rendus invariants à l'aide de mesures supplémentaires dans la scène comme la profondeur [Kluckner et al., 2007]. À titre d'exemple, les algorithmes de détection de véhicules proposés par [Kim et Malik, 2003; Khammari et al., 2005] peuvent atteindre des taux de performance supérieurs à 90% et des taux de fausses alarmes inférieurs à 5% sur des images de véhicules sur route.

3.1.2 Description et modélisation

La détection abordée précédemment constitue l'étape préliminaire à la reconnaissance. Une fois l'objet détecté, la région d'intérêt est décrite. Le vecteur descripteur est utilisé à la fois pour l'apprentissage des modèles (ou du classifieur) et pour la classification d'une nouvelle observation. Ce principe est illustré par la figure 1.1. Comme pour la détection, le choix du descripteur conditionne la performance de la reconnaissance. Ce choix est lié à la nature même des objets. La difficulté inhérente à la reconnaissance de véhicules est due à la grande variété de modèles se distinguant souvent par des éléments de détail. À cela s'ajoutent des réflexions importantes, et une description et modélisation trop simples sont souvent inefficaces [Gupte et al., 2002].

Les modèles polyédriques paramétriques de [Koller et al., 1993; Li et al., 2008] permettent une classification des véhicules selon leur type (sedan, pick-up, hatchback, ...). Toutefois, l'ajout d'un descripteur d'apparence est jugé nécessaire par les auteurs pour améliorer les performances de la reconnaissance. [Ozcanli et al., 2006] exploite la combinaison de la silhouette et de l'apparence des véhicules par l'utilisation de "shock graphs" pour la reconnaissance. [Thureson et Carlsson, 2004] utilisent le gradient pour capturer indirectement la silhouette des objets, tandis que [Guinet, 2008] associe une modélisation polyédrique à l'apparence locale dans une comparaison multi-vues de véhicules. Un inconvénient de l'approche polyédrique, soulevé au chapitre 1, est cependant la difficulté à appairer les modèles aux contours de l'image du à une combinatoire importante. Ces modèles sont de plus une approximation des objets et nécessitent un appariement robuste. Des a priori sur la scène, tel que la calibration de la caméra, sont généralement nécessaires pour pallier ces difficultés. De tels a priori ne sont pas envisagés ici.

Les véhicules étant formés par des surfaces localement planes, les petites variations de pose peuvent être assimilées localement à des transformations affines. Cela a conduit à de nombreuses approches par modèles de constellation qui offrent une robustesse élevée face à ce type de variations sans nécessiter de calibration précise [Dorkó et Schmid, 2003; Lazebnik et al., 2004; Fergus et al., 2005; Epshtein et Ullman, 2006]. Les véhicules étant pauvres en texture, la recherche de zones locales discriminantes est généralement basée sur la combinaison de plusieurs détecteurs de points d'intérêt [Dorkó et Schmid, 2003; Fergus et al., 2005] ou par d'autres critères tels que l'entropie [Ullman et al., 2002], ou encore le découpage sémantique de l'objet [Leibe et al., 2008]. Cependant, l'invariance affine de ces modèles reste limitée [Moreels et Perona, 2007]. [Savarese et Fei-Fei, 2007] proposent une généralisation des modèles de constellation à la reconnaissance 3D de véhicules en estimant des vues canoniques à partir de la stabilité de l'apparence locale. La classification est réalisée entre plusieurs types d'objets avec une performance de plus de 75%, mais la classification au sein de la catégorie véhicules n'est pas envisagée dans ces travaux. L'avantage des modèles de constellation réside également dans leur capacité à détecter et à discriminer l'objet simultanément, notamment à l'aide du principe de vote de Hough (tel que mis en œuvre dans les modèles de silhouette implicites de [Leibe et al., 2004]).

Une troisième catégorie de description pour la reconnaissance 3D de véhicules est basée sur l'apparence des objets. Les vecteurs descripteurs des images (les pixels) sont réduits par ACP et forment une variété géométrique dans l'espace de représentation initial [Nayar et al., 1996]. L'évolution sur cette variété est liée à l'évolution des CPDV. Plusieurs auteurs comme [Borotschnig et al., 1998; Winkeler et al., 1999; Paletta et Pinz, 2000; Sipe et Casasent, 2002] ou encore [Roy et Kulkarni, 2004] mettent en œuvre une modélisation similaire pour la reconnaissance active de véhicules. Cependant, cette stratégie de description nécessite une étape de segmentation dont la qualité conditionne fortement le résultat de la reconnaissance. Elle est très sensible aux variations d'illumination ainsi qu'à la présence d'objets parasites et d'occultations [LeCun et al., 2004].

Une modélisation par variété d'apparence est envisagée dans la suite (section 3.2.2). Elle diffère cependant des approches existantes par l'utilisation d'un descripteur par histogrammes au lieu des données brutes directes (les pixels), permettant ainsi d'améliorer la robustesse de la description.

3.2 CONSTRUCTION DES MODÈLES

Le cadre formel établi au chapitre 2 pour la reconnaissance repose sur la connaissance d'une série de paramètres θ modélisant les caractéristiques des objets à reconnaître. Ces paramètres doivent rendre compte des spécificités de chaque classe (i.e. augmenter la variance inter-classe) tout en expliquant l'ensemble des variabilités des objets (i.e. réduire la variance intra-classe). Une part de ces variabilités, dues à l'incertitude sur les modalités d'acquisition, est abordée à la section 3.2.1. La prise en compte des autres variations et une modélisation de vraisemblance est réalisée à la section 3.2.1.

3.2.1 Incertitude sur les modalités d'acquisition

La densité $P(x_{t+1} | v_{t+1}, \omega)$, qui intervient dans le schéma d'accumulation de l'information (2.10), est issue du classifieur. Elle fournit la vraisemblance d'une observation à partir de la connaissance des modalités d'acquisition et de la classe. Elle modélise les variations d'apparence de l'objet dues à l'acquisition (bruit, occultations). Elle suppose un placement certain de l'observateur dans les modalités planifiées. Ce placement est cependant difficilement réalisable car il dépend d'actionneurs souvent imprécis. Ce phénomène est illustré par la figure 2.2. Pour cela, une incertitude sur ces modalités est prise en compte.

Elle conduit à conditionner sur un ensemble de modalités probabilisées plutôt que sur une modalité unique. La modélisation de l'imprécision du placement de l'observateur consiste à définir une distribution des modalités réellement atteintes, notées v_r , conditionnée aux modalités planifiées (ou théoriques), notées v_{t+1} :

$$P(v_r | v_{t+1}) \quad (3.1)$$

Ce modèle d'incertitude intervient dans l'estimation de la vraisemblance de la manière suivante :

$$\begin{aligned} P(x_{t+1} | v_{t+1}, \omega) &= \int_{\mathcal{V}} P(x_{t+1} | v_r, \omega) P(v_r | v_{t+1}, \omega) dv_r \\ &= \int_{\mathcal{V}} P(x_{t+1} | v_r, \omega) P(v_r | v_{t+1}) dv_r \end{aligned} \quad (3.2)$$

Notons que la probabilité (3.2) peut également intervenir dans la recherche de stratégies de planification. En intégrant l'incertitude sur le placement de l'observateur dans l'élaboration de ces stratégies, celles-ci seront à même d'offrir les performances souhaitées dans des situations réalistes où le placement du porteur est incertain.

3.2.2 Modélisation de densité

Les modèles d'objets sont représentés par un ensemble de paramètres noté θ . L'estimation des modèles est elle-même un problème inverse. La difficulté liée à la résolution des problèmes inverses a été abordée au chapitre 1. L'objectif poursuivi ici consiste à déterminer les paramètres $\{\theta_1, \dots, \theta_K\}$ pour chacune des classes à partir des données d'apprentissage de manière à prédire la vraisemblance (3.2) de toute nouvelle observation. L'estimateur du paramètre θ_k est noté $\hat{\theta}_k$. Pour le modèle k , les mesures issues d'un objet de la classe k doivent conduire à une vraisemblance forte, alors que les mesures d'un objet de la classe $j \neq k$, doivent au contraire conduire à une vraisemblance faible.

Cette vraisemblance de l'observation à l'instant $t + 1$ est liée au classifieur élémentaire (3.2) par le biais de (2.2) de la manière suivante :

$$\begin{aligned} P(x_{t+1} | v_{t+1}, \omega = k) &= \int_{\Theta} P(\theta | \omega = k) \int_{\mathcal{V}} P(x_{t+1} | v_r, \theta) P(v_r | v_{t+1}) dv_r d\theta \\ &= \int_{\mathcal{V}} P(x_{t+1} | v_r, \hat{\theta}_k) P(v_r | v_{t+1}) dv_r \end{aligned} \quad (3.3)$$

La densité $P(x_{t+1} | v_r, \theta)$ est le résultat de la confrontation de la mesure aux modèles. La probabilité $P(\theta | \omega = k)$ est ici caractérisée par l'indicatrice qui est égale à un lorsque θ correspond à la valeur estimée $\hat{\theta}_k$ des paramètres du modèle k , et zéro sinon.

Les modèles (i.e. les paramètres θ) doivent prendre en compte les variations intra-classe des mesures pour assurer leur bonne généralisation. Ces variations sont capturées lors de la phase d'estimation, par un apprentissage de $P(x | v, \theta)$ qui est une densité de probabilité dans l'espace de représentation \mathcal{X} .

L'apprentissage de $P(x | v, \theta)$ est cependant complexe. En particulier, il nécessite l'estimation de la densité pour chaque valeur de v qui appartient à un espace continu. Une discrétisation de l'espace \mathcal{V} sur une grille régulière pourrait être envisagée, mais nécessiterait une quantité de données d'apprentissage très importante. Ce problème peut être résolu en remarquant que le classifieur élémentaire (3.2), qui inclue l'incertitude des modalités d'acquisition, a un comportement invariant par l'équivalence

$$P(x_{t+1} | v_r, \hat{\theta}_k) P(v_r | v_{t+1}) \equiv P(x_{t+1} | \hat{\theta}_k) P(v_r | v_{t+1}) \quad (3.4)$$

Cette équivalence est justifiée par le fait que la vraisemblance de l'observation x_{t+1} associée à des modalités v_r éloignées de v_{t+1} sera pénalisée par le terme $P(v_r | v_{t+1})$ indépendamment de $P(x_{t+1} | v_r, \theta)$. L'équation (3.3) devient :

$$P(x_{t+1} | v_{t+1}, \omega = k) = \int_{\mathcal{V}} P(x_{t+1} | \hat{\theta}_k) P(v_r | v_{t+1}) dv_r \quad (3.5)$$

Par conséquent, modéliser les objets revient à déterminer un modèle de densité sur \mathcal{X} pour obtenir $P(x | \theta)$.

Modèles de mélange gaussien

L'estimation des modèles de densité nécessite une information a priori pour résoudre le problème inverse. Cet a priori est introduit par la restriction de θ à un sous espace, ce qui revient à considérer une famille de fonctions de densités paramétriques. La famille de fonctions choisie pour la modélisation est le mélange gaussien. Celui-ci est formé par une somme de M fonctions gaussiennes appelées modes. Il permet une représentation multimodale, parfois complexe des données tout en conservant une manipulation mathématique aisée. La fonction de densité est donnée par :

$$\begin{aligned} P(x | \theta_k) &= g_M(x, \theta_k) \\ &= \sum_{m=1}^M \frac{\alpha_m}{(2\pi)^{\frac{d}{2}} \sqrt{\det(\Sigma_m)}} \exp \left[-\frac{1}{2} (x - \mu_m)^T \Sigma_m^{-1} (x - \mu_m) \right] \end{aligned} \quad (3.6)$$

où $\theta_k = (\alpha_m, \mu_m, \Sigma_m)_k$, $m = 1, \dots, M$, $k = 1, \dots, \mathcal{K}$. Le terme α_m est la proportion telle que $\sum_{m=1}^M \alpha_m = 1$, μ_m la moyenne et Σ_m la matrice de covariance associée au mode m . d est la dimension de l'espace de représentation. En considérant la matrice de covariance diagonale, le nombre de paramètres à estimer pour un mélange gaussien contenant M modes est $(2d + 1)M - 1$.

Estimation par maximum de vraisemblance

La famille de modèles de densité étant choisie, les paramètres θ_k de chaque modèle doivent être estimés de manière optimale. Un critère d'optimalité couramment utilisé en statistiques est le critère du maximum de vraisemblance. Notons que la fonction de *vraisemblance* est dans ce cas rattachée à une notion différente de celle utilisée précédemment. Elle est ici définie par une fonction $\theta \rightarrow V(\cdot, \theta)$. À l'aide du modèle de densité (3.6), et en notant $\{x_1, \dots, x_{N_k}\}$ l'ensemble des N_k observations d'apprentissage pour le modèle k , sous l'hypothèse i.i.d. des observations, nous avons :

$$L(x_1, \dots, x_{N_k}, \theta_k) = \prod_{j=1}^{N_k} g_M(x_j, \theta_k) \quad (3.7)$$

La recherche du maximum de vraisemblance se traduit donc par la recherche des paramètres $\hat{\theta}_k$ tels que la vraisemblance des observations de la classe k soit maximale :

$$\hat{\theta}_k = \operatorname{argmax}_{\theta_k \in \Theta} L(x_1, \dots, x_{N_k}, \theta_k) \quad (3.8)$$

La vraisemblance est parfois remplacée par la log-vraisemblance dont le comportement est identique. Elle est définie par :

$$LL(x_1, \dots, x_{N_k}, \theta_k) = \sum_{j=1}^{N_k} \log g_M(x_j, \theta_k) \quad (3.9)$$

Cette optimisation peut être complexe, et le maximum peut ne pas exister ou ne pas être unique. Cependant, dans le cas des mélanges gaussiens, cette recherche est facilitée par l'utilisation du très populaire algorithme espérance-maximisation (EM) [Dempster et al., 1977]. Celui-ci permet, à travers un processus d'estimation itératif et en utilisant la log-vraisemblance (3.9), d'obtenir rapidement une valeur approchée satisfaisante des paramètres.

Le succès de l'algorithme EM repose cependant sur une étape d'initialisation des paramètres qui doit être suffisamment proche du résultat final. Cette initialisation est l'objet du paragraphe suivant.




FIGURE 3.2 – Illustration de l'estimation de densité par mélange gaussien en dimension 2 ; a. : données d'apprentissage ; b. : initialisation du nombre de modes et de leur position par agglomération ; c. : estimation de la densité de probabilité par l'algorithme EM

Initialisation des paramètres pour l'algorithme EM

Pour un nombre de modes M fixé, leurs proportions et leurs matrices de covariance peuvent être initialisées de manière uniforme. Leurs positions initiales (les moyennes μ_m) conditionnent en revanche particulièrement la qualité du modèle et nécessitent d'être initialisées à une valeur proche de leur position finale. L'initialisation des moyennes μ_m de chaque mode a été obtenue par agglomération (en anglais : *clustering*) des données dans l'espace de représentation. L'algorithme K -means [MacQueen et al., 1967] (où $K = M$ dans le cas présent) a été utilisé. La qualité des agglomérats obtenus a été évaluée à partir de la distance moyenne entre les centroïdes et les points agglomérés. L'algorithme K -means nécessite lui-même une initialisation des centroïdes. Cette initialisation a été réalisée en tirant aléatoirement et sans remise M points parmi les données. Son coût de calcul étant faible, plusieurs tirages initiaux peuvent être effectués. L'agglomération finale retenue est celle conduisant à la meilleure qualité mesurée.

La figure 3.2 illustre la procédure de modélisation des objets dans un espace de représentation de dimension $d = 2$.

Complexité des modèles

La complexité de la fonction d'estimation de densité au sein de la famille considérée conditionne le succès de la reconnaissance. Une trop faible complexité ne permet pas de capturer les spécificités de chaque classe, tandis qu'une complexité trop forte s'expose au sur-apprentissage. Cette complexité est fonction du nombre de paramètres indépendant intervenant dans le modèle. Ce choix résulte de la recherche d'une erreur de généralisation minimale. Cependant, cette erreur est souvent difficile à estimer et nécessite des données de test (i.e. n'ayant pas servi à l'apprentissage) supplémentaires. Plusieurs critères ont été proposés pour estimer cette l'erreur de généralisation à partir de l'erreur sur les données d'apprentissage. Deux critères sont en particulier applicables lorsque la fonction de prédiction est estimée à partir de la log-vraisemblance (3.9). Le premier d'entre eux, le critère d'information d'Akaike [Akaike, 1974] (AIC), est défini par

$$\text{AIC}(M) = -2 \sum_{j=1}^{N_k} \log(g_M(x_j, \hat{\theta}_k)) + 2((2d + 1)M - 1) \quad (3.10)$$

Une erreur d'apprentissage faible conduit généralement à des modèles très complexes et à un sur-apprentissage. Pour éviter ce phénomène, un terme de pénalisation est ajouté. La minimisation de ce critère définit l'optimalité du nombre de modes. Le facteur 2 provient de la définition de l'erreur de généralisation dans le cas d'une fonction de perte définie par la log-vraisemblance et de l'ajout d'une erreur additive [Hastie et al., 2009].

Un deuxième critère, le critère d'information de Bayes (BIC) est défini par

$$\text{BIC}(M) = -2 \sum_{j=1}^{N_k} \log(g_M(x_j, \hat{\theta}_k)) + \log(N_k)((2d + 1)M - 1) \quad (3.11)$$

Le critère BIC (au facteur 2 près) est également appelé le critère de Schwarz [Schwarz, 1978]. Son comportement est similaire à l'AIC, mais la pénalisation est fonction de la quantité de données. En supposant que $N_k > e^2 \approx 7,4$, le critère BIC tend à pénaliser davantage les modèles complexes par rapport à l'AIC. Cette différence de comportement provient d'une approche bayésienne de sélection du modèle, faisant intervenir le facteur de Bayes. D'un point de vue informationnel, il est proche d'une sélection basée sur la recherche de la description la plus courte (ou du code le plus court) pour décrire les données [Hastie et al., 2009].

Les critères BIC et AIC sont cependant basés sur une considération générale et indirecte de l'optimalité. Un modèle complexe peut s'avérer nécessaire et plus efficace pour une tâche particulière, même s'il ne conduit pas à la valeur optimale de ces critères, car l'estimation de l'erreur de généralisation demeure approximative. Lorsque des données tests sont disponibles, l'erreur de généralisation peut être estimée directement sur celles-ci. Le critère d'optimalité de la complexité du modèle est dans ce cas beaucoup plus proche de l'objectif final, qui est la performance de reconnaissance à partir de la modélisation obtenue.

3.3 DISPOSITIF EXPÉRIMENTAL

Le dispositif expérimental mis en œuvre dans cette thèse est décrit dans cette section. Il permet à la fois l'estimation des modèles et l'évaluation des algorithmes de reconnaissance active.

3.3.1 Constitution de la base de données

La base de données est constituée de douze classes de véhicules. Elle est illustrée par la figure 3.3. À l'aide du dispositif expérimental de la figure 3.5, les données ont été acquises à une cadence vidéo. Une première rotation complète autour de chaque objet a permis d'acquérir les données d'apprentissage, représentant environ 1000 images par classe. Par commodité, les images de test ont été collectées à l'avance au cours d'un deuxième processus d'acquisition. Chaque image a ensuite été annotée par la pose (l'azimut) relative de l'objet par rapport à la caméra. L'annotation de la pose a été réalisée à l'aide des quatre mires de part et d'autre de l'objet, visibles sur la figure 3.5. Une calibration de la caméra a été utilisée uniquement pendant la phase d'apprentissage. Elle permet la reprojction du repère caméra dans la scène 3D et la détermination de la matrice de passage vers le repère formé par les mires (pour plus de détails sur l'étape de calibration et d'annotation des images, se référer à l'annexe A). Enfin, une étape de normalisation des images a été appliquée. Les objets ont été centrés sur des vignettes de taille 100×100 pixels.

Les modalités d'acquisition considérées dans ce dispositif expérimental sont les CPDV qui se résument ici à l'azimut, c'est-à-dire que $\mathcal{V} = \mathbb{R}$.

3.3.2 Description des objets

La représentation des images est basée sur le descripteur GLOH¹ [Mikolajczyk et Schmid, 2005]. Il est formé par la concaténation d'une série d'histogrammes d'orientation du gradient de l'image répartis sur une grille spatiale polaire. La figure 3.4 illustre la procédure de description. Chaque histogramme de la grille quantifie l'orientation sur huit niveaux,

1. *Gradient Location and Orientation Histogram.*



FIGURE 3.3 – Base de données utilisée pour les validations expérimentales

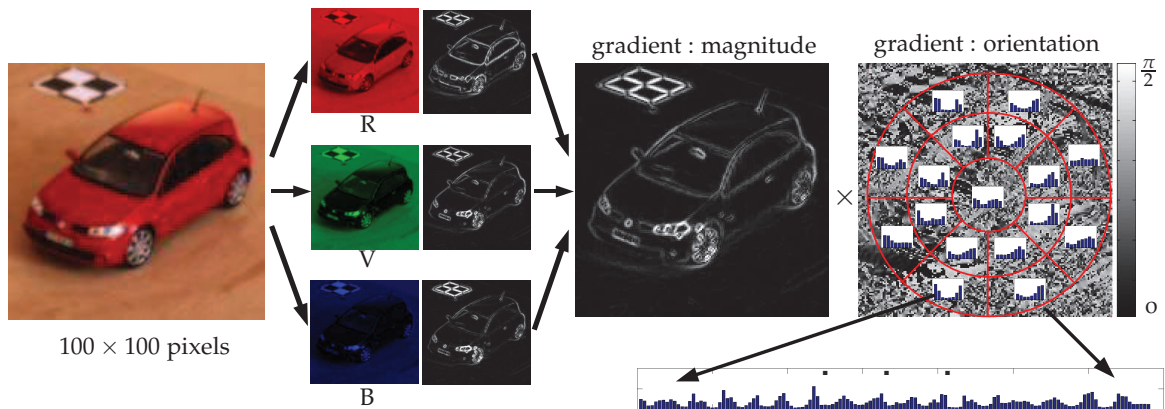


FIGURE 3.4 – Représentation des images par le descripteur GLOH.

aboutissant à un descripteur GLOH de dimension 136. Le descripteur final est obtenu par projection dans une base de dimension $d < 136$. Ce sous espace est obtenu par analyse en composantes principales (ACP) sur les données d'apprentissage de l'ensemble des classes. La part de variance totale expliquée par chaque composante principale est illustrée par la figure 3.6. Elle indique une répartition très déséquilibrée en faveur des premières composantes qui semblent suffisantes pour résumer le comportement des données.

3.3.3 Détermination de la complexité optimale des modèles

La détermination du nombre de modes optimal a été effectuée à l'aide des critères AIC (3.10), BIC (3.11), ainsi que par validation sur des données de test afin d'établir une comparaison. La performance sur les données de test a été obtenue à partir du taux moyen de classification sur 200 observations par classe (les CPDV étant choisies au hasard). Notons que la connaissance de la pose associée aux images n'est pas nécessaire pour la modélisation ni pour cette évaluation. La figure 3.7 illustre l'évolution de ces trois critères en fonction du nombre de modes M et pour plusieurs dimensions d de l'espace de représentation des données.

Discussion

Les résultats obtenus par les différents critères font apparaître plusieurs constats. Premièrement, le nombre optimal de modes diffère d'un critère à l'autre. Pour $d = 3$ et 5, les critères BIC et AIC privilégient une complexité de modélisation plus faible, alors que pour $d = 7$ une plus forte complexité est requise par rapport au dernier critère (l'erreur de test). La complexité optimale donnée par l'erreur de test est quant à elle plus constante avec d , en favorisant un nombre de modes compris entre 14 et 18. Ce dernier critère, plus proche de l'erreur de généralisation du classifieur, semble préférable pour l'application considérée. Pour l'ensemble des expérimentations qui seront menées dans les chapitres suivants, les valeurs $d = 5$ et $M = 16$ seront choisies.




FIGURE 3.5 – Dispositif expérimental utilisé pour la reconnaissance active. Les quatre mires sont utilisées pour l'annotation de la pose sur les images d'apprentissage.

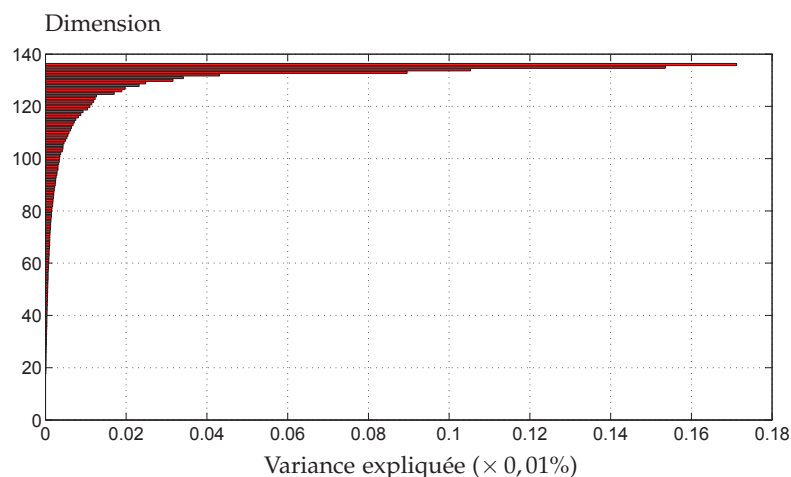


FIGURE 3.6 – Variance expliquée par les composantes principales des descripteurs GLOH sur la base de données considérée.

Un deuxième phénomène constaté est une amélioration des performances globales de classification lorsque la dimension des données augmente. Une plus grande dimension permet en effet d'augmenter la séparabilité des données, (i.e. la variance inter-classe) et conduit dans ce cas à une erreur de généralisation plus faible. Néanmoins, ces résultats sont à considérer avec quelques précautions. Les données de test sont proches des données d'apprentissage. Elles sont donc susceptibles de conserver une vraisemblance élevée avec l'augmentation du nombre de modes, et peuvent par conséquent favoriser le sur-apprentissage. Il faut se rappeler que lorsque le classifieur est basé sur une estimation de densité, une dimension trop importante de l'espace de représentation n'est pas souhaitable pour assurer la bonne généralisation du classifieur, car la quantité de données d'apprentissage serait insuffisante face à des espaces de plus en plus creux.

Nous pouvons également remarquer que la performance moyenne de reconnaissance obtenue par cette modélisation est inférieure à d'autres approches rencontrées dans la littérature pour la reconnaissance 3D (voir par exemple [Thomas et al., 2009]). Cependant, cette performance est supérieure à celle d'une classification aléatoire qui est de $\frac{1}{\mathcal{K}}$, \mathcal{K} étant le nombre de classes. De plus, la classification n'est réalisée qu'à partir d'une seule observation. Ce taux d'erreur ne reflète aucunement la performance de la reconnaissance active qui, en plus de combiner plusieurs observations, sélectionne les plus informatives. Enfin, cette stratégie de modélisation adoptée possède un grand avantage : elle est simple à mettre en œuvre. Elle est conforme à la volonté sous-jacente de la reconnaissance active qui est de transférer en partie l'effort de modélisation vers la recherche de CPDV discriminantes.

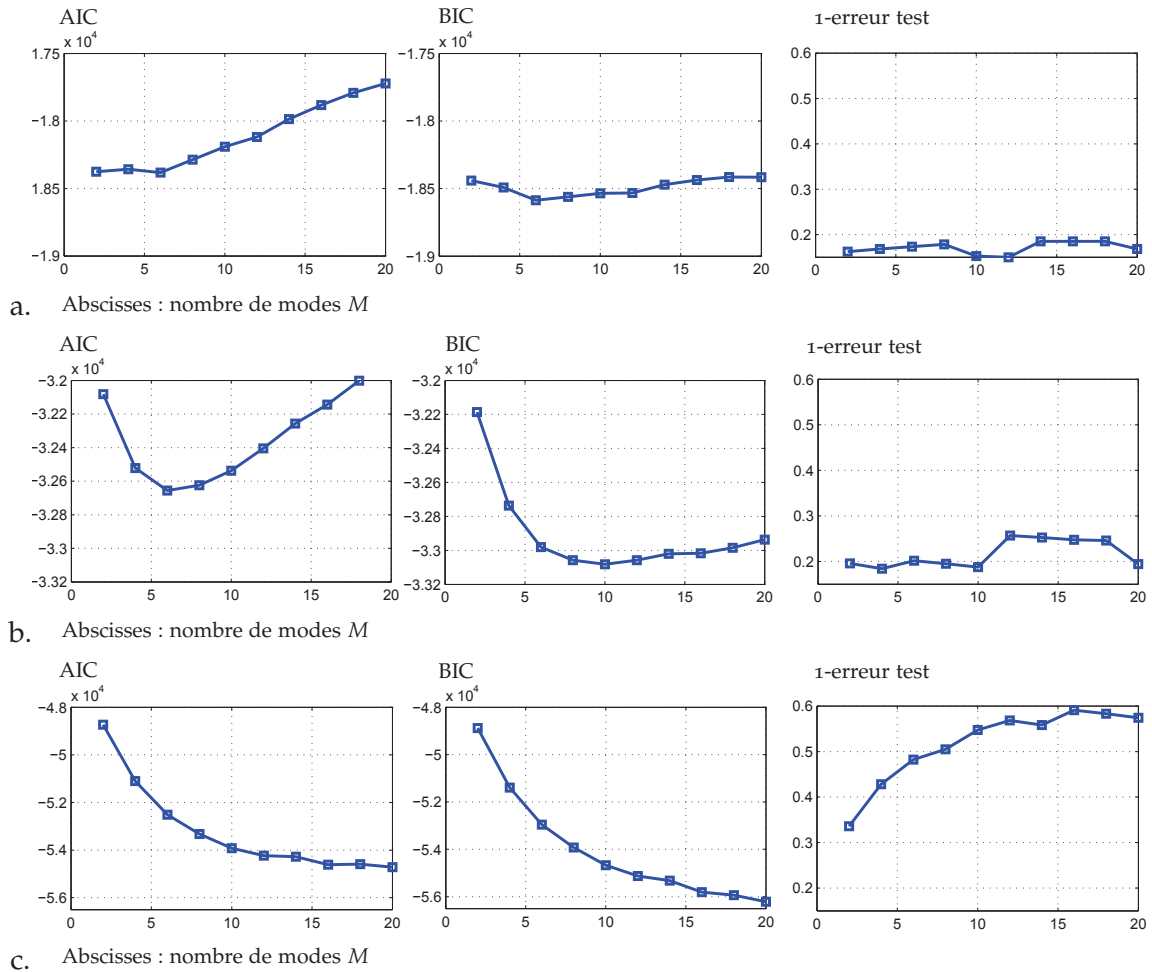


FIGURE 3.7 – Résultats des critères BIC, AIC, et du critère de performance sur les données test pour la sélection du nombre de modes M des modèles. Dimension des modèles ; a. : $d = 3$; b. : $d = 5$; c. : $d = 7$.

CONCLUSION DU CHAPITRE

Dans ce chapitre, une modélisation des objets a été définie, permettant une mise en œuvre expérimentale de la reconnaissance multi-observations. Des modèles de vraisemblances, dont la généralisation a été optimisée à l'aide de critères de performance, ont été construits. Une modélisation de l'incertitude sur les CPDV, qui traduit l'imprécision du placement de l'agent, a été associée à la modélisation. Ces modèles, combinés au formalisme du chapitre 1 et aux stratégies de planification abordées dans la partie suivante, ouvrent la voie vers une reconnaissance active.

PARTIE 2
PLANIFICATION DES CONDITIONS DE
PRISE DE VUE POUR UNE
RECONNAISSANCE ACTIVE

DE LA PLANIFICATION PAR L'AMBIGUÏTÉ VERS UN CRITÈRE ADAPTATIF

4

La première partie de cette thèse s'est intéressée d'une part à la formalisation mathématique de la reconnaissance active (au chapitre 2) et d'autre part à la modélisation des objets (au chapitre 3) pour une mise en œuvre de la reconnaissance. Cependant, la modélisation adoptée a révélé des imperfections se traduisant par des erreurs de classification. Ces imperfections sont indissociables d'un cadre applicatif réaliste. Ce chapitre a pour but de proposer une stratégie de planification des modalités d'acquisition lorsque les modèles d'objets utilisés pour la reconnaissance sont imparfaits. L'étude porte en particulier sur le cas où les modalités sont des CPDV. En plus des similarités intrinsèques entre les objets, les défauts de modélisation sont également une source d'ambiguïté pour le classifieur. Les similarités intrinsèques sont généralement capturées par une mesure classique de l'ambiguïté, l'entropie. Celle-ci permet de sélectionner les CPDV informatives. L'efficacité de l'entropie se révèle cependant limitée face à une modélisation imparfaite (section 4.1). Pour pallier cette limitation, la contribution apportée consiste en la définition d'un nouveau critère, dit critère adaptatif (section 4.2). Par une prise en compte plus fine du comportement du classifieur, ce critère permet une planification en ligne qui s'adapte non seulement à l'état actuel du système mais également à la modélisation disponible. Ce nouveau critère, ainsi qu'une variante, sont mis en œuvre pour la reconnaissance active de véhicules et évalués à l'aide du protocole expérimental défini au chapitre 3.

PLAN DU CHAPITRE

Ce chapitre est organisé de la manière suivante : à la section 4.1, un rappel de l'état de l'art sur les critères de planification utilisés en reconnaissance active est effectué. Une définition formelle de l'entropie pour la reconnaissance active, point de départ de la définition du critère adaptatif est donnée (section 4.1.2). Les sources d'erreur de modélisation sont analysées et la faiblesse de l'entropie face à celle-ci est mise en évidence (section 4.1.4). Le nouveau critère de planification proposé est décrit à la section 4.2. Les résultats obtenus par ce critère sont présentés à la section 4.3 et leur discussion est reportée à la section 4.4.

4.1 REVUE ET LIMITATIONS DES APPROCHES EXISTANTES

4.1.1 Rappels de l'état de l'art

La planification des CPDV en reconnaissance active est guidée par une recherche des observations discriminantes. Le formalisme établi au chapitre 1 a permis d'établir le lien entre la séquence d'observations acquises, le résultat du classifieur et la recherche de modalités d'acquisition informatives pour la reconnaissance. La sélection de ces modalités, exprimée par la distribution (2.13), nécessite la définition d'un critère adéquat. Celui-ci est généralement obtenu à partir de données d'apprentissage annotées. Cette approche, où l'agent *apprend à planifier*, est mise en œuvre dans ce chapitre.

Dans le cadre de la sélection de caractéristiques discriminantes pour la classification, [Guyon et Elisseeff, 2003] met en évidence deux stratégies d'évaluation de la performance du critère de sélection : l'approche "wrapper" et l'approche "filter". La distinction est faite respectivement selon une prise en compte directe de l'objectif final (qui est ici le résultat de la classification) pour l'évaluation, ou bien par une évaluation indirecte. Les travaux existants en reconnaissance active mettent également en œuvre ces deux approches pour la sélection des CPDV.

Une méthode "filter" très utilisée consiste à mesurer l'information espérée de CPDV particulières par l'entropie (au sens de Shannon) [Cover et al., 1991]. La définition formelle de cette mesure est établie à la section 4.1.2. Une forte entropie est synonyme de forte ambiguïté entre les classes. Les travaux de [Callari et Ferrie, 1996b,a] furent précurseurs dans la planification des CPDV par l'entropie pour la reconnaissance d'objet à partir de leurs silhouettes. Cette mesure est également mise en œuvre par [Arbel et Ferrie, 2001] pour la reconnaissance d'objets à partir de la signature de leurs mouvements, ou encore par [Kappen et al., 1995] pour une recherche séquentielle active de caractéristiques discriminantes d'un objet sur une image. L'entropie est à la base de plusieurs autres critères aux comportements très similaires, dont les dénominations se déclinent en information mutuelle [Denzler et Brown, 2000, 2002], transinformation [Schiele et Crowley, 2002], ou gain d'information [Borotschnig et al., 2000]. L'entropie et ses déclinaisons offrent l'avantage de s'appuyer directement sur le cadre probabiliste de la reconnaissance. Elle offre en particulier une compatibilité d'utilisation naturelle avec la modélisation générative adoptée. Le calcul de cette mesure est indépendante du descripteur d'image utilisé et de la manière de dériver les vraisemblances (3.2). Contrairement au critère de sélection proposé dans [Sipe et Casasent, 2002], qui définit les uniques CPDV informatives pour discriminer chaque paire de classes, l'entropie permet de fournir une liste ordonnée de CPDV informatives et est donc adaptée à l'aspect séquentiel de la reconnaissance active. Cependant, l'ensemble de ces travaux est basé sur l'hypothèse d'une modélisation parfaite des objets : en l'absence de similarité intrinsèque, la classe de l'objet sort vainqueur de la classification. Mais cette mesure indirecte s'avère insuffisante dans le cas où le classifieur confond les classes, à cause des imperfections des modèles. Ce phénomène est abordé à la section (4.1.4).

L'approche "wrapper" quant à elle base la sélection des CPDV directement sur l'objectif

final du problème : la capacité du classifieur à discriminer les classes. Plusieurs travaux utilisent cette approche. [Kovacic et al., 1998] définissent cette capacité à discriminer par une distance euclidienne entre les données d'apprentissage dans l'espace de représentation. Par un découpage récursif de ces données dans l'espace de représentation, la séquence optimale des CPDV est extraite de manière à disperser au maximum les données pour diminuer l'ambiguïté. Ce critère est cependant sensible au bruit sur les données et à la variance inter-classes (qui n'ont pas été considérés) ainsi qu'au choix du seuil sur la distance. Une mesure plus robuste basée sur l'analyse discriminante linéaire a été proposée par [Laporte et al., 2004]. Les approches "wrapper" existantes sont cependant spécifiques au cadre discriminatif pour la reconnaissance, et excluent l'utilisation de modèles génératifs. De surcroît, la prise en compte de la qualité de la modélisation constitue un problème non soulevé dans l'ensemble des approches précédentes. Ce problème est cependant inhérent en reconnaissance automatique.

La définition d'un critère de sélection des CPDV sous la contrainte précédente est au centre de ce chapitre. Une approche "wrapper" est considérée, en combinaison avec une modélisation générative des objets. Cette approche est proche des cartes d'entropie définies par [Arbel et Ferrie, 2001], à la différence que le critère de sélection des CPDV est directement basé sur le résultat de la reconnaissance à partir des modèles disponibles. L'adaptativité du critère est double : d'une part, en s'adaptant à l'état actuel du système au cours de la reconnaissance, il permet une planification en ligne. D'autre part, en évitant les CPDV pour lesquelles le résultat espéré du classifieur est mauvais, la planification s'adapte à la modélisation disponible.

Le principe de la planification par l'ambiguïté à l'aide de l'entropie et les limitations de cette mesure sont abordés à la section suivante.

4.1.2 L'entropie comme mesure de l'ambiguïté

La planification par l'ambiguïté consiste à sélectionner les CPDV pour lesquelles l'observation de l'objet conduit à une classification non ambiguë : la vraie classe sort vainqueur de la classification avec une confiance maximale. Une mesure d'ambiguïté très utilisée pour la planification est l'entropie. Sa popularité dans de nombreux domaines a conduit naturellement à son utilisation pour la reconnaissance active. L'entropie est au cœur de la théorie de l'information due à Shannon [Cover et al., 1991]. Le problème consiste à quantifier l'information que contient un signal circulant entre une source et un récepteur. Ce cas de figure est applicable à la reconnaissance active [Denzler et Brown, 2000]. La source (l'objet lui-même) émet des données visuelles voyageant à travers l'environnement et le système optique de l'agent pour obtenir une image reçue contenant une information pour la classification. Cette information reçue peut cependant avoir subi des changements ou des dégradations au cours de la transmission. Plusieurs phénomènes peuvent en être à l'origine : bruits, occultations, similarités intrinsèques entre les objets, information a priori ou encore modèles imparfaits modifient la quantité d'informations reçues (souvent en la diminuant). La figure 4.1 illustre cette analogie de la reconnaissance avec la théorie de l'information. La diminution de la quantité d'information est synonyme d'ambiguïté. L'entropie est fondée sur la notion de quantité d'information, il est nécessaire d'introduire la notion d'information. L'information au sens de Shannon est liée à la probabilité d'occurrence d'un événement, qui est ici le résultat du classifieur. Cet événement contient d'autant plus d'information qu'il est rare. Cette propriété est retrouvée dans la définition de l'information :

$$\mathcal{I}_\Omega(\omega | x, v) = -\log P(\omega | x, v) \quad (4.1)$$




FIGURE 4.1 – Source, récepteur, et modélisation du canal d'information.

où $P(\omega | x, v)$ est la probabilité a posteriori (2.3) issue du classifieur. L'entropie est définie par l'information moyenne :

$$\begin{aligned} \mathcal{E}_\Omega(\omega | x, v) &= \sum_{\omega \in \Omega} P(\omega | x, v) \mathcal{I}_\Omega(\omega | x, v) \\ &= - \sum_{\omega \in \Omega} P(\omega | x, v) \log P(\omega | x, v) \end{aligned} \quad (4.2)$$

Pour mesurer la qualité des CPDV à l'aide de l'entropie, il est nécessaire de définir la mesure d'ambiguïté comme fonction de v uniquement. Cette fonction est obtenue en calculant l'espérance de l'entropie relativement à l'observation x . Deux cas de figure sont considérés selon les observations prises en compte dans le calcul de (4.2).

Dans le premier cas, les observations de tous les modèles sont considérées. Cela conduit à la définition de l'entropie moyenne :

$$\begin{aligned} \mathcal{E}_\Omega(\omega | v) &= \mathbb{E}_{x, v_r | v} \mathcal{E}_\Omega(\omega | x, v) \\ &= \int_{\mathcal{X}} \int_{\mathcal{V}} \mathcal{E}_\Omega(\omega | x, v_r) P(x | v_r) P(v_r | v) dv_r dx \end{aligned} \quad (4.3)$$

Dans le deuxième cas, l'espérance est calculée sur l'espace d'observation \mathcal{X} , mais sous l'hypothèse que la classe $\omega_{\text{hyp}} = k$ est observée. Par conséquent, seul le modèle de vraisemblance $P(x | v, \omega_{\text{hyp}} = k)$ intervient dans le calcul de l'entropie, conduisant à la définition de \mathcal{K} mesures d'entropies conditionnelles où $\mathcal{K} = \text{card } \Omega$. L'entropie conditionnelle est alors définie par

$$\begin{aligned} \mathcal{E}_\Omega(\omega | v) &= \mathbb{E}_{x, v_r | v, k} \mathcal{E}_\Omega(\omega | x, v) \\ &= \int_{\mathcal{X}} \int_{\mathcal{V}} \mathcal{E}_\Omega(\omega | x, v_r) P(x | v_r, \omega_{\text{hyp}} = k) P(v_r | v) dv_r dx, \quad k = 1, \dots, \mathcal{K} \end{aligned} \quad (4.4)$$

Le calcul pratique des équations (4.3) et (4.4) est donné à la section 4.3.1. Dans les deux cas, une valeur élevée de l'entropie implique une ambiguïté forte entre les classes pour les CPDV considérées. La valeur maximale est atteinte lorsque la distribution est uniforme sur Ω (toutes les classes sont équiprobables). Il en résulte une faible capacité discriminante de ces CPDV qui devraient être exclues de la planification pour la reconnaissance. Au contraire, les CPDV conduisant à une faible valeur de l'entropie sont celles qui devraient être sélectionnées prioritairement. Ce comportement est illustré par la figure 4.2 dans le cas de deux classes.

4.1.3 Planification par entropie en ligne et hors ligne

Les équations (4.3) et (4.4) conduisent à deux approches différentes de la planification par entropie. La première (équation (4.3)) est qualifiée de planification hors ligne. Les CPDV utiles au sens de ce critère ont une ambiguïté moyenne faible. Elles sont définies




FIGURE 4.2 – Évolution de l'entropie d'une distribution en fonction de la probabilité des événements. Illustration pour $\mathcal{K} = 2$.

à l'avance, une fois pour toutes, et sont sélectionnées quel que soit l'objet observé. L'entropie hors ligne est utilisée par [Kappen et al., 1995; Borotschnig et al., 2000]. La seconde approche est qualifiée de planification en ligne. La définition des \mathcal{K} critères conduit à une planification en deux étapes : (i) la sélection d'un seul critère $\mathcal{E}_\Omega(\omega | v, k)$, et (ii) la sélection des CPDV informatives selon le critère choisi. La première étape (la sélection du critère) est réalisée à partir de l'état actuel du système au cours de la reconnaissance, c'est-à-dire en choisissant k à partir de l'hypothèse courante sur la classe de l'objet. Cela traduit l'aspect en ligne de la planification. Cette approche est adoptée par [Callari et Ferrie, 1996b; Denzler et Brown, 2002]. [Arbel et Ferrie, 2001; Arbel, 2000] utilisent ce dernier critère à travers des cartes d'entropie.

4.1.4 Limites de l'entropie pour la planification

L'écueil de l'entropie pour la planification des CPDV vient de la surjectivité de cette mesure : plusieurs combinaisons des probabilités a posteriori sont susceptibles d'aboutir à la même valeur. Cette propriété peut se révéler particulièrement néfaste avec le schéma d'intégration bayésien (2.10) utilisé pour la reconnaissance lorsque les modèles sont imparfaits. La figure 4.3 illustre ce phénomène dans le cas de la recherche de CPDV les plus discriminantes pour un classifieur binaire. Dans le cas où l'objet observé est $\omega = 1$, le comportement attendu du classifieur est de maximiser la probabilité $P(\omega = 1 | \mathbf{X}_t, \mathbf{V}_t, x_{t+1}, v_{t+1})$ avec la prochaine mesure (x_{t+1}, v_{t+1}) . Cela revient à maximiser la vraisemblance $P(x_{t+1} | v_{t+1}, \omega = 1)$ intervenant dans le chaînage bayésien (2.10). L'entropie calculée préalablement à l'aide des données d'apprentissage fait cependant apparaître deux CPDV v_{t+1} et v'_{t+1} équivalentes au sens de l'information (l'entropie est minimale). À cause des défauts de modélisation, ces niveaux d'entropie sont obtenus pour des combinaisons différentes des probabilités a posteriori, ce qui se traduit par une confusion du classifieur. Ces défauts de modélisation peuvent avoir plusieurs causes :

- Une nouvelle observation peut être bruitée ou occultée. Le classifieur est alors susceptible de confondre entre plusieurs classes si les modèles des objets ne sont pas robustes à ces changements.
- Les données d'apprentissage peuvent être dégradées. Les modèles et le classifieur sont alors appris de manière à discriminer des observations trop différentes de celles acquises au cours de la reconnaissance.
- La famille de modèles peut être inadaptée. Ces modèles, généralement paramétriques, sont susceptibles de ne pas capturer la totalité de l'information contenue dans les données d'apprentissage.

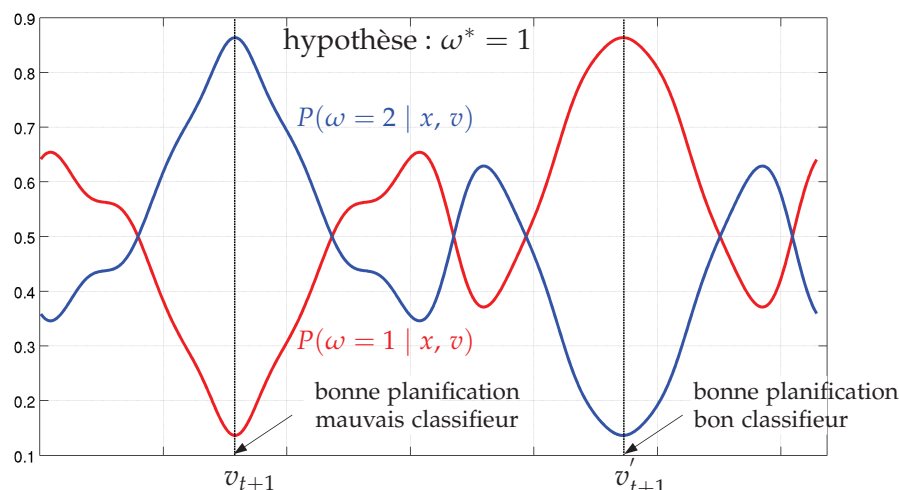


FIGURE 4.3 – Illustration de la surjectivité de la mesure d'entropie. Plusieurs combinaisons des probabilités a posteriori conduisent à la même entropie mais n'ont pas le même effet pour la reconnaissance.

Dans le cas de v_{t+1} , l'observation est plus vraisemblable sous l'hypothèse $\omega = 2$ que sous l'hypothèse $\omega = 1$. Le classifieur est alors influencé vers la mauvaise décision. La planification par entropie, qu'elle soit en ligne ou hors ligne, ne permet pas de capturer ce phénomène, car elle demeure toujours une approche de type "filter". Dans la section suivante, un critère capable de pallier cette limitation est proposé. Contrairement à l'entropie, le critère utilisé est basé sur une approche "wrapper" qui permet, en plus de capturer les similarités intrinsèques entre les objets, de capturer également les imperfections des modèles utilisés pour la reconnaissance. Une planification en ligne est également proposée. De cette manière, la sélection des CPDV est basée non seulement sur l'apprentissage, mais aussi sur le résultat actuel du classifieur.

4.2 PLANIFICATION ADAPTATIVE

La section précédente a montré que l'entropie n'était pas suffisante à elle seule pour sélectionner les CPDV informatives car elle ne prend pas en compte les défauts des modèles. Une adaptation de la planification aux modèles est nécessaire. Cette section présente un nouveau critère pour répondre à ce besoin.

4.2.1 Adaptation en ligne de la planification

Reprenons l'exemple illustré figure 4.3. Pour identifier l'objet $\omega = 1$, les CPDV v'_{t+1} devraient être sélectionnées prioritairement, tandis que les CPDV v_{t+1} devraient au contraire être rejetées. Cette différence entre v_{t+1} et v'_{t+1} , non perceptible par l'entropie, peut cependant être capturée lors de l'apprentissage par le biais des vraisemblances $P(x | v, \omega)$ ou, de manière équivalente, par les probabilités a posteriori $P(\omega | x, v)$. La planification des CPDV repose alors sur la tendance actuelle du classifieur, ce qui conduit à la définition suivante du critère de planification adaptatif.

Étant donnée l'hypothèse courante de la classe de l'objet fournie par le classifieur, le critère adaptatif sélectionne les prochaines CPDV de manière à :

- 1 - minimiser l'ambiguïté entre les classes ;
- 2 - confirmer l'hypothèse courante ;

Il est défini par :

Critère adaptatif

$$\mathcal{C}_\Omega(\omega \mid v_{t+1}, k) = -(1 - \alpha) \frac{\mathcal{E}_\Omega(\omega \mid v_{t+1})}{\mathcal{E}_0} + \alpha \mathbb{E}_{x_{t+1}, v_r \mid v_{t+1}} P(\omega = k \mid x_{t+1}, v_{t+1}),$$

$$k = 1, \dots, \mathcal{K}. \quad (4.5)$$

où le terme de normalisation $\mathcal{E}_0 = -\log \text{card}(\Omega)$. Ce critère combine la mesure de l'ambiguïté par l'entropie et l'espérance du résultat du classifieur sous les CPDV planifiées, permettant d'assurer que ce dernier soit favorable à l'hypothèse courante. Cette combinaison est contrôlée par le paramètre α . L'espérance sur la probabilité a posteriori permet de prendre en compte l'incertitude sur les CPDV réellement atteintes v_r , de la même manière que pour l'entropie (équation (4.3)).

Notons que l'espérance de la probabilité a posteriori $\mathbb{E}_{x_{t+1}, v_r \mid v_{t+1}} P(\omega = k \mid x_{t+1}, v_{t+1})$ permet également de capturer l'ambiguïté entre les objets, car une forte probabilité pour l'hypothèse k se traduit automatiquement par une faible probabilité pour l'ensemble des autres classes, donc une faible entropie.

Une variante du critère adaptatif (4.5) consiste à utiliser non pas la probabilité a posteriori mais l'écart relatif entre $P(\omega = k \mid x_{t+1}, v_{t+1})$ et le maximum a posteriori. Cela conduit à la définition du critère max-adaptatif.

Critère max-adaptatif

$$\mathcal{C}_\Omega(\omega \mid v_{t+1}, k) = -(1 - \alpha) \frac{\mathcal{E}_\Omega(\omega \mid v_{t+1})}{\mathcal{E}_0}$$

$$+ \alpha \mathbb{E}_{x_{t+1}, v_r \mid v_{t+1}} \left[P(\omega = k \mid x_{t+1}, v_{t+1}) - \max_{\substack{i \in \Omega \\ i \neq k}} P(\omega = i \mid x_{t+1}, v_{t+1}) \right]$$

$$, k = 1, \dots, \mathcal{K}. \quad (4.6)$$

Ces deux critères permettent de mettre à profit à la fois l'information calculée hors ligne pendant l'apprentissage et la connaissance actuelle accumulée pour la planification. Le problème de la surjectivité de l'entropie est ainsi résolu. Dans le cas où l'hypothèse courante k est la classe de l'objet, la prédiction d'une vraisemblance forte de la prochaine observation par le critère sera vérifiée et le classifieur renforcera sa décision. Dans le cas contraire, si k n'est pas la bonne hypothèse, la vraisemblance prédite par le critère ne sera pas vérifiée et sera alors inférieure. La prochaine observation infirmera la décision du classifieur, conduisant à la génération d'une nouvelle hypothèse.

4.2.2 Algorithme de reconnaissance active avec critère adaptatif

La mise en œuvre des critères adaptatif (4.5) et max-adaptatif (4.6) pour la planification des CPDV en reconnaissance active est résumée par l'algorithme 2 qui est une version modifiée de l'algorithme 1 (cf. section 2.4.2). Après chaque observation, la planification en ligne consiste en la sélection du critère adéquat selon l'hypothèse courante. Notons que le classifieur peut ne pas prendre de décision si le budget de T observations ne permet pas d'atteindre le niveau de confiance requis P_{\max} .

Algorithme 2: Reconnaissance active avec critère de planification adaptatif

Entrées : modèles : $P(x \mid \omega = k, v)$, $k = 1, \dots, \mathcal{K}$
 $\mathcal{C}_\Omega(\omega \mid v_{t+1}, k)$, $k = 1, \dots, \mathcal{K}$
 α, tol, P_{\max}, T
conditions initiales : x_1, v_1

Sorties : classe de l'objet ω^* ou rejet

- 1 $t \leftarrow 0$;
- 2 $\mathbf{X}_t = \emptyset$; $\mathbf{V}_t = \emptyset$;
- 3 **répéter**
- 4 $P(v \mid \mathbf{X}_t, \mathbf{V}_t, \omega) = \mathbf{1}_{\{v=v_{t+1}\}}$;
- 5 $\mathbf{X}_{t+1} \leftarrow \mathbf{X}_t \cup x_{t+1}$;
- 6 $\mathbf{V}_{t+1} \leftarrow \mathbf{V}_t \cup v_{t+1}$;
- 7 calculer $P(\omega \mid \mathbf{X}_{t+1}, \mathbf{V}_{t+1})$, $\omega \in \Omega$ (éq. (2.11));
- 8 $k^* \leftarrow \underset{k}{\operatorname{argmax}} P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t)$;
- 9 $t \leftarrow t + 1$;
- 10 $\mathcal{C}^* \leftarrow \mathcal{C}_\Omega(\omega \mid v_{t+1}, k^*)$ (éq. (4.5) ou (4.6));
- 11 $v_{t+1}^* = \underset{v_{t+1}}{\operatorname{argmax}} \mathcal{C}^*$, tel que $[v_{t+1} - tol; v_{t+1} + tol] \cap \mathbf{V}_t = \emptyset$;
- 12 aller à v_{t+1}^* ; observer x_{t+1} ;
- 13 **jusqu'à** $\max_k P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t) \geq P_{\max}$ ou $t = T$;
- 14 **si** $P(\omega = k^* \mid \mathbf{X}_t, \mathbf{V}_t) \geq P_{\max}$ **alors**
- 15 **retourner** k^* ;
- 16 **sinon**
- 17 **rejet**;

4.3 ÉVALUATIONS

Une série d'expérimentations a été réalisée pour évaluer les performances de la planification adaptative pour la reconnaissance active de véhicules. Trois aspects ont été analysés. Tout d'abord, une comparaison entre les critères par entropie hors ligne et en ligne (section 4.3.2). Ensuite, l'apport du critère adaptatif par rapport à l'entropie seule (section 4.3.3) et l'influence du paramètre α . Enfin, une comparaison entre les critères adaptatif et max-adaptatif (section 4.3.4).

4.3.1 Dispositif expérimental et modélisation des objets

Le dispositif expérimental est identique à ceux des chapitres précédents et est décrit en section 3.3. Le déplacement de l'agent s'effectue sur un degré de liberté : la sélection des CPDV s'effectue selon l'azimut (figure 3.5). La base de données considérée comprend huit classes d'objets, représentés à la figure 4.4. Le descripteur GLOH [Mikolajczyk et Schmid, 2005] a été utilisé pour représenter les données. La représentation des objets est basée sur la modélisation générative. Cette modélisation ainsi que la mise en œuvre du descripteur sont décrites à la section 3.1. Pour les expérimentations, la dimension du descripteur a été fixée à $d = 5$, et le nombre de mode considéré dans les modèles de vraisemblance à $M = 14$. Les performances du classifieur issu de cette modélisation sont illustrées à la Table 4.1 par le biais de la matrice de confusion. Ces performances sont issues d'une moyenne sur deux cents tests par classe. Chaque test a consisté en l'acquisition d'une seule observation, les CPDV ayant été choisies selon une loi uniforme sur \mathcal{V} . La classification a été obtenue par maximum a posteriori (équation (2.12)). Le taux de performance moyen



FIGURE 4.4 – Base de données utilisée pour la reconnaissance.

	0,25	0,15	0,39	0,05	0,03	0,05	0,06	0,02
	0,25	0,19	0	0,07	0,08	0,09	0,14	0,19
	0,16	0,01	0,39	0,21	0,04	0,07	0,10	0
	0,10	0,08	0,04	0,73	0	0,04	0,01	0
	0,04	0,12	0,03	0,02	0,17	0,37	0,12	0,12
	0,05	0,06	0,05	0,33	0,08	0,43	0	0
	0,19	0,24	0	0	0	0,08	0,14	0,35
	0,10	0,17	0	0	0,01	0,07	0,11	0,54

TABLE 4.1 – Matrice de confusion du classifieur utilisé. Les résultats sont obtenus par une moyenne sur 200 tests par classe.

du classifieur est égal à 0,35. Notons qu’une classification aléatoire parmi les huit classes conduirait à un taux de performance égal à 0,125. Le classifieur est donc en moyenne plus performant qu’une classification aléatoire. La matrice de confusion révèle cependant des taux d’erreur non nuls (termes en dehors de la diagonale) et parfois supérieurs au taux d’erreur du classifieur aléatoire. Cela traduit la présence de défauts de modélisation (le classifieur confond les classes).

Critères de performance

Les critères de performance des stratégies de planification évaluées sont décrits à la section 2.4.3. Ils sont rappelés ci-dessous :

- *Performance maximale* ($Perf_{\max}$) : elle correspond à la performance cumulée de reconnaissance pour $t = T$. Elle doit être la plus élevée possible (i.e. égale à 1).
- *Nombre moyen d’observations* (T_{moy}) : il correspond à la moyenne (en nombre d’observations) de la courbe de performance cumulée. Il doit être le plus faible possible (sa valeur minimale étant $(T + 1)/2$).
- *Aire sous la courbe de performance cumulée* ($Aire_T$) : elle permet d’évaluer la performance globale de la reconnaissance. Elle est en particulier un indicateur intéressant pour comparer les stratégies de planification entre elles. Elle doit être la plus élevée possible (égale à $T - 1$ pour une reconnaissance dès la première observation).

Ces critères sont complémentaires. Leur optimisation simultanée définit l’optimalité de la politique de planification.

Construction des cartes de planification

L'implémentation des critères par entropie (équations (4.3) et (4.4)) et adaptatif (équations (4.5) et (4.6)) a été effectuée en substituant les intégrales par des sommes discrètes et en utilisant les observations d'apprentissage (x_i, v_i) ainsi que les distributions a posteriori $P(\omega \mid x_{t+1}, v_{t+1})$ apprises (cf. chapitre 3). La discrétisation de l'espace des CPDV a été obtenue à l'aide d'une grille régulière avec un pas de un degré. Une carte de planification a donc été obtenue par 360 évaluations du critère sur l'azimut. L'étape de maximisation sur ces cartes de planification (ligne 12 de l'algorithme 2) est réalisée par une recherche exhaustive sur la grille obtenue. L'incertitude sur la pose est modélisée par une distribution gaussienne centrée sur v_{t+1} d'écart-type trois degrés (cf. section 3.2.1 pour le détail de cette modélisation). L'estimation des critères à partir des observations d'apprentissage est donnée par les équations suivantes

Entropie :

$$\widehat{\mathcal{E}}_{\Omega}(\omega \mid x_j, v_j) = - \sum_{\omega \in \Omega} P(\omega \mid x_j, v_j) \log P(\omega \mid x_j, v_j) \quad (4.7)$$

Entropie moyenne :

$$\widehat{\mathcal{E}}_{\Omega}(\omega \mid v) = \frac{\sum_{j=1}^N \widehat{\mathcal{E}}_{\Omega}(\omega \mid x_j, v_j) P(v_j \mid v)}{\sum_{j=1}^N P(v_j \mid v)} \quad (4.8)$$

Entropie conditionnelle :

$$\widehat{\mathcal{E}}_{\Omega}(\omega \mid v, k) = \frac{\sum_{j=1}^{N_k} \widehat{\mathcal{E}}_{\Omega}(\omega \mid x_j, v_j) P(v_j \mid v)}{\sum_{j=1}^{N_k} P(v_j \mid v)}, \quad k = 1, \dots, \mathcal{K} \quad (4.9)$$

Critère adaptatif :

$$\widehat{\mathcal{C}}_{\Omega}(\omega \mid v, k) = -(1 - \alpha) \frac{\widehat{\mathcal{E}}_{\Omega}(\omega \mid v)}{\mathcal{E}_0} + \alpha \frac{\sum_{j=1}^{N_k} P(\omega = k \mid x_j, v_j) P(v_j \mid v)}{\sum_{j=1}^{N_k} P(v_j \mid v)}, \quad k = 1, \dots, \mathcal{K} \quad (4.10)$$

Critère max-adaptatif :

$$\begin{aligned} \widehat{\mathcal{C}}_{\Omega}(\omega \mid v, k) = & -(1 - \alpha) \frac{\widehat{\mathcal{E}}_{\Omega}(\omega \mid v)}{\mathcal{E}_0} \\ & + \alpha \left[\frac{\sum_{j=1}^{N_k} P(\omega = k \mid x_j, v_j) P(v_j \mid v)}{\sum_{j=1}^{N_k} P(v_j \mid v)} \right. \\ & \left. - \max_{\substack{j \in \Omega \\ j \neq k}} \frac{\sum_{i=1}^{N_j} P(\omega = j \mid x_i, v_i) P(v_i \mid v)}{\sum_{i=1}^{N_j} P(v_i \mid v)} \right], \quad k = 1, \dots, \mathcal{K} \quad (4.11) \end{aligned}$$

N représente le nombre total d'observations d'apprentissage, et N_k le nombre d'observations d'apprentissage de la k -ème classe, avec $N = \sum_k N_k$. Dans les deux derniers critères, $\mathcal{E}_0 = -\log(\text{card}(\Omega))$.

4.3.2 Première analyse : comparaison entre l'entropie moyenne et l'entropie conditionnelle

Une première comparaison a été effectuée entre le critère par entropie moyenne (4.3) et par entropie conditionnelle (4.4). Dans l'ensemble des expériences, le paramètre tol , qui définit une zone d'exclusion autour des CPDV visitées, a été fixé à trois degrés. La carte d'entropie moyenne (4.8) est représentée à la figure 4.5, tandis que les huit cartes




FIGURE 4.5 – Carte d’entropie moyenne calculée sur l’ensemble des modèles de la base (cf. figure 4.4). Les 5 CPDV les plus discriminantes sont également représentées ($tol = 3$ degrés).

d’entropies conditionnelles (correspondantes aux huit classes de la base considérées) sont représentées à la figure 4.6. Les cinq CPDV les plus informatives (i.e. à entropie minimale) sont indiquées pour chaque carte. Dans le cas de l’entropie moyenne (où la planification est hors ligne), ces CPDV seront sélectionnées systématiquement et dans l’ordre indiqué pendant la reconnaissance, quel que soit l’état courant du système. Dans le cas de l’entropie conditionnelle (où la planification est en ligne), le choix des CPDV est réalisé en deux étapes : la carte de planification est tout d’abord sélectionnée parmi les \mathcal{K} cartes possibles selon l’état courant du système (l’hypothèse actuelle de la classe), puis les CPDV sont sélectionnées à partir de cette carte. La comparaison entre les figures 4.5 et 4.6 montre que l’entropie en ligne sélectionne des CPDV différentes de celles sélectionnées par l’entropie moyenne et variables selon l’hypothèse courante.

Performances

La figure 4.7 illustre les performances par le biais des critères $Aire_T$ et $Perf_{max}$ (avec $T = 20$) pour différentes valeurs du seuil de décision P_{max} . Une comparaison avec la planification aléatoire (i.e. une sélection des CPDV selon une loi uniforme) a également été réalisée. Plusieurs phénomènes apparaissent :

- Tout d’abord, toutes les courbes sont décroissantes avec P_{max} , conséquence du compromis entre le niveau de confiance recherché et la quantité globale d’information nécessaire pour atteindre ce niveau. Cette information est d’autant plus importante (et donc d’autant plus difficile à obtenir) que le niveau de confiance requis est élevé. Par conséquent, lorsque P_{max} augmente, le taux de rejet augmente et les performances s’en trouvent diminuées.
- La planification par l’entropie moyenne ou conditionnelle est moins performante que la planification aléatoire. Ceci peut s’expliquer par la surjectivité de cette mesure d’ambiguïté (cf. section 4.1.4), dans un contexte de modélisation imparfaite. La planification aléatoire est plus efficace car dans ce cas une mauvaise combinaison des probabilités a posteriori est en moyenne moins fréquente.

La figure 4.8 (gauche) montre que le critère T_{moy} est légèrement à l’avantage de l’entropie conditionnelle. Mais ce seul avantage ne suffit pas à imposer l’entropie conditionnelle (ni l’entropie moyenne) comme un critère acceptable pour la reconnaissance active pour l’application considérée. Finalement, la limitation de l’entropie pour la planification est visible sur les courbes de performance cumulée (figure 4.8, droite) dont le comportement n’est guère supérieur à la planification aléatoire.




FIGURE 4.6 – Cartes d'entropies conditionnelles calculées pour chaque modèle de la base (figure 4.4). Les 5 CPDV les plus discriminantes sont représentées ($\text{tol} = 3$ degrés).

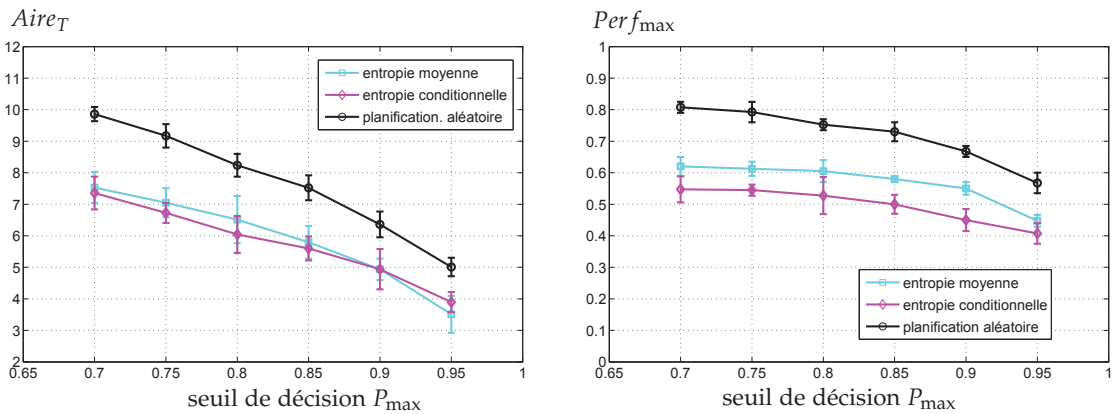


FIGURE 4.7 – Comparaison entre les critères de planification par entropie moyenne et entropie conditionnelle en fonction du seuil de décision P_{\max} ; à gauche : aire sous les courbes de performance cumulée; à droite : performance maximale (pour $T = 20$).

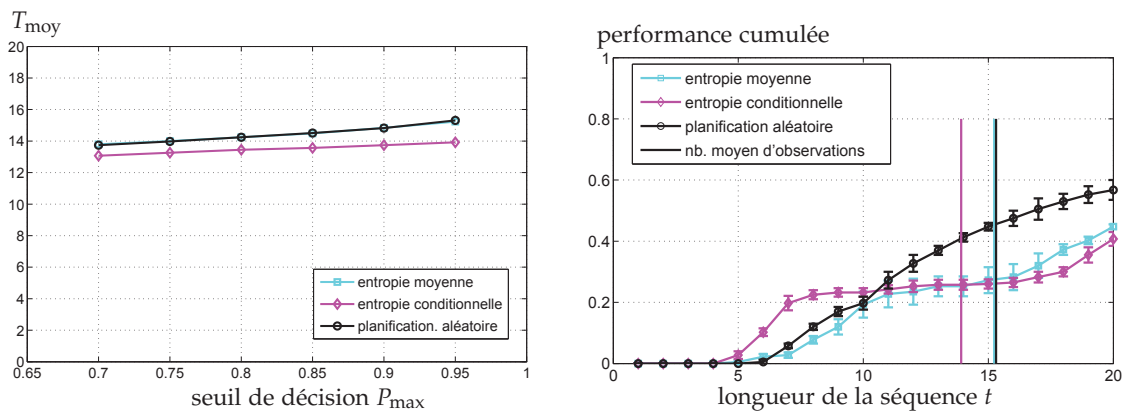


FIGURE 4.8 – Comparaison entre les critères de planification par entropie moyenne et entropie conditionnelle; à gauche : longueur moyenne de la séquence en fonction du seuil de décision P_{\max} ; à droite : performance cumulée moyenne sur l'ensemble des classes et longueur de séquence moyenne pour $P_{\max} = 0,95$.

4.3.3 Deuxième analyse : critère adaptatif. Évaluation et influence du paramètre α

La deuxième série d'expérimentations réalisée permet d'évaluer le bénéfice apporté par le critère adaptatif (4.5) et la valeur optimale du paramètre α . Seule l'entropie moyenne est considérée dans ce critère. Le choix de l'entropie conditionnelle est également possible, mais les performances des deux critères entropiques étant semblables, ce choix est sans conséquence sur les résultats obtenus.

Le calcul des cartes de planification adaptative a été réalisé par le biais de l'équation (4.10). La figure 4.9 illustre les huit cartes obtenues pour $\alpha = 1$.

Performances

Comme le montre la figure 4.10, le critère adaptatif conduit à une valeur de $Aire_T$ sensiblement supérieure quel que soit le seuil de décision P_{\max} . Pour $\alpha > 0,8$, la valeur de $Aire_T$ obtenue par le critère adaptatif surpasse celle obtenue par planification aléatoire dès que $P_{\max} > 0,8$. Le critère adaptatif permet d'exploiter plus efficacement l'information disponible de la scène pour atteindre le niveau de confiance requis. Pour des valeurs de P_{\max} plus faibles, la planification aléatoire reste plus efficace. Cela peut s'expliquer par la stratégie utilisée par le critère adaptatif : celui-ci vise à confirmer l'hypothèse actuelle sur la classe de l'objet. Du fait des défauts de modélisation, cette hypothèse est susceptible d'être fautive et d'être maintenue telle quelle tout au long de la reconnaissance jusqu'à atteindre le niveau de confiance (faible) requis, ce qui peut s'avérer plus néfaste que la planification aléatoire.

Le bénéfice du critère adaptatif est atteint lorsque $\alpha = 1$ ($Aire_T$ atteint sa valeur maximale). L'influence de l'entropie dans le critère adaptatif est nulle dans ce cas, et la planification est basée uniquement sur l'espérance de la probabilité a posteriori. Celle-ci se révèle donc capable non seulement de capturer les défauts de modélisation, mais aussi les similarités intrinsèques entre les classes (jusqu'à là mesurées par l'entropie).

Pour $P_{\max} = 0,95$, la valeur de $Perf_{\max}$ (à $T = 20$) obtenue par le critère adaptatif est semblable à celle obtenue par planification aléatoire. La convergence vers cette valeur est en revanche plus rapide, et le nombre moyen d'observations requis (figure 4.11), est inférieur quel que soit P_{\max} . Le critère adaptatif est donc ici beaucoup plus approprié pour la reconnaissance active avec des modèles imparfaits.




FIGURE 4.9 – Cartes de planification par critère adaptatif ($\alpha = 1$). Pour chaque carte, les 5 CPDV les plus discriminantes sont représentées ($\text{tol} = 3$ degrés).

4.3.4 Troisième analyse : comparaison entre les critères adaptatif et max-adaptatif

La dernière série d'expérimentations réalisée vise à comparer les performances des critères adaptatif (4.5) et max-adaptatif (4.6). Ceux-ci ont en pratique été calculés respectivement à l'aide des équations (4.10) et (4.11). La planification par le critère max-adaptatif est également basée sur la performance espérée du classifieur, estimée pendant l'apprentissage. L'information sur cette performance espérée est cette fois capturée par l'écart entre le MAP et la probabilité a posteriori de l'hypothèse courante. En sélectionnant les CPDV de manière à maximiser cet écart, ce critère conduit également à confirmer l'hypothèse courante sur la classe de l'objet. La figure 4.12 illustre les cartes de planification obtenues par le critère max-adaptatif pour $\alpha = 1$.

Les figures 4.13 et 4.14 reportent les performances comparatives de ces deux critères pour $\alpha = 1$. Bien que les résultats soient très proches en terme de nombre moyen d'ob-




FIGURE 4.10 – Comparaison entre les critères de planification par entropie moyenne et par critère adaptatif en fonction du seuil de décision P_{\max} ; à gauche : aire sous les courbes de performance cumulée; à droite : performance maximale (pour $T = 20$). Les résultats sont issus d'une moyenne sur l'ensemble des classes de la base.

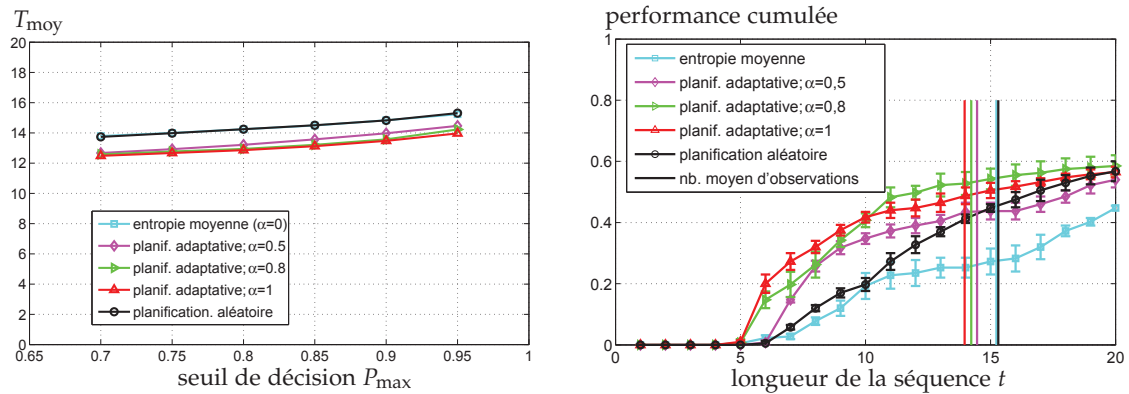


FIGURE 4.11 – Comparaison entre les critères de planification par entropie moyenne et par critère adaptatif; à gauche : longueur moyenne de la séquence en fonction du seuil de décision P_{max} ; à droite : performance cumulée moyenne en fonction du nombre d'observations t pour $P_{\text{max}} = 0,95$ et nombres moyens d'observations. Les résultats sont issus d'une moyenne sur l'ensemble des classes de la base.

servations (T_{moy}), le critère max-adaptatif semble plus performant en moyenne pour les critères $Aire_T$ et $Perf_{\text{max}}$. Les performances cumulées pour chaque classe sont représentées à la figure 4.15, tandis que les courbes de rejet moyen pour les deux critères sont données par la figure 4.16 (gauche). Ces courbes représentent le taux d'absence de décision (i.e. lorsque le seuil P_{max} n'est pas atteint) en fonction de la longueur de la séquence t . Plus le nombre d'observations augmente, plus la quantité d'information collectée est importante, et plus l'agent est à même de prendre une décision, d'où la décroissance des courbes. Les critères adaptatif et max-adaptatif aboutissent à des taux de rejet moyen beaucoup plus faibles que celui obtenu par la planification aléatoire. En effectuant une recherche active de l'information, ces critères permettent une prise de décision plus systématique : le taux de rejet diminue et, simultanément, le taux de performance augmente (figure 4.14).

Un exemple de reconnaissance à l'aide du critère max-adaptatif et des cartes de planification associées est illustré par la figure 4.17. La première vue est choisie au hasard, puis la planification est réalisée à partir des critères. Les deux premières observations conduisent à l'hypothèse $\omega = 3$ qui est fautive. À la troisième observation, l'hypothèse change pour $\omega = 4$, ce qui correspond au comportement attendu du classifieur. Les trois dernières observations permettent de valider cette hypothèse jusqu'à atteindre le seuil de confiance P_{max} requis.




FIGURE 4.12 – Cartes de planification par critère max-adaptatif ($\alpha = 1$). Pour chaque carte, les 5 CPDV les plus discriminantes sont représentées (tol = 3 degrés).

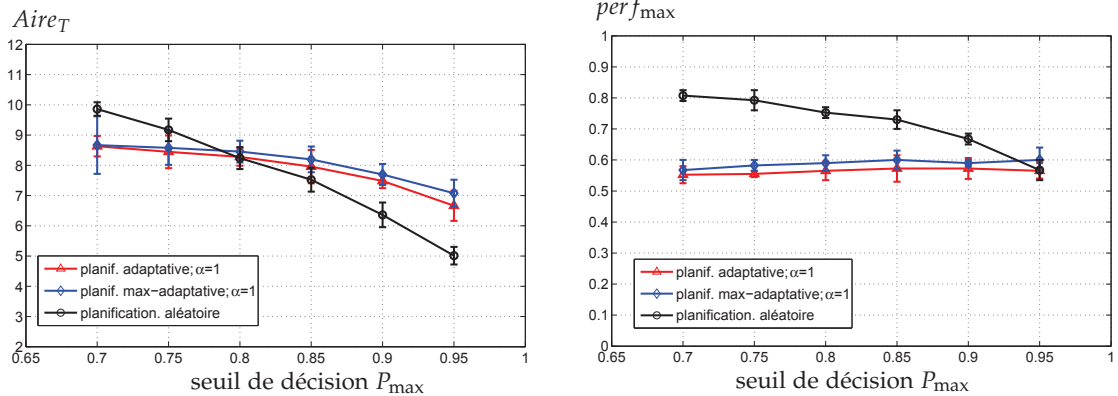


FIGURE 4.13 – Comparaison entre les critères de planification adaptatif et max-adaptatif ($\alpha = 1$) en fonction du seuil de décision P_{\max} ; gauche. Aire sous les courbes de performance cumulée; droite. Performance maximale (pour $T = 20$). Les résultats sont issus d'une moyenne sur l'ensemble des classes de la base.

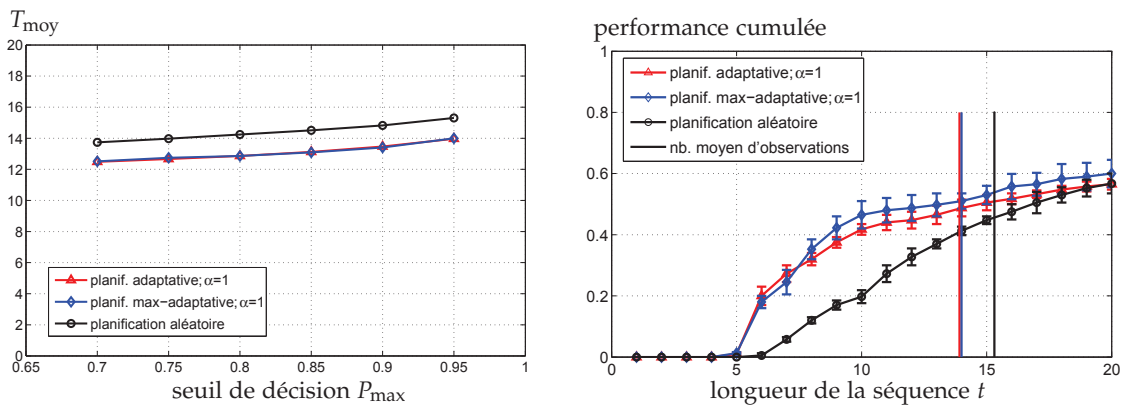


FIGURE 4.14 – Comparaison entre les critères de planification adaptatif et max-adaptatif ($\alpha = 1$); gauche. Longueur moyenne de la séquence en fonction du seuil de décision P_{\max} ; droite. Performance cumulée moyenne en fonction du nombre d'observations t pour $P_{\max} = 0,95$ et nombres moyens d'observations. Les résultats sont issus d'une moyenne sur l'ensemble des classes de la base.

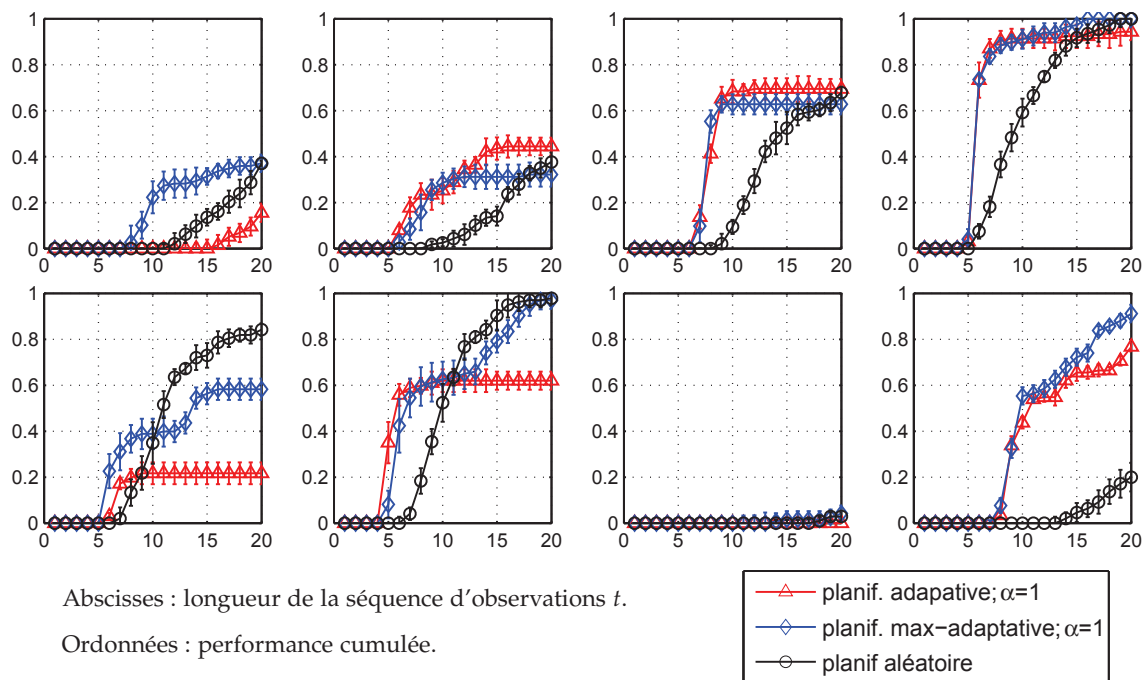


FIGURE 4.15 – Performances de reconnaissance cumulées pour chaque classe avec planification par critère max-adaptatif ($\alpha = 1$).

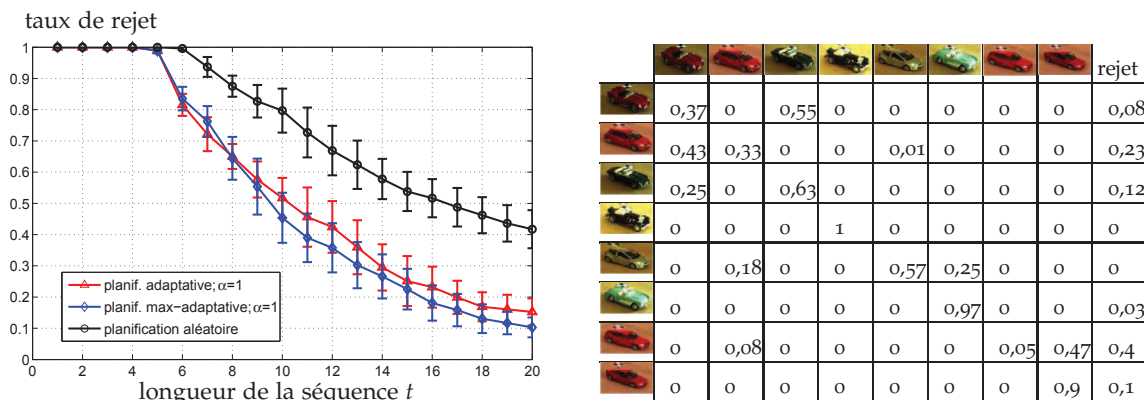


FIGURE 4.16 – À gauche : taux de rejet en fonction de la longueur de la séquence pour $P_{\max} = 0,95$; à droite : matrice de confusion obtenue à l'aide du critère de planification max-adaptatif pour $T = 20$ et $P_{\max} = 0,95$

4.4 DISCUSSIONS

L'ensemble des expérimentations a montré que la valeur $\alpha = 1$ apparaît optimale pour la planification par les critères adaptatif et max-adaptatif. Le comportement de ces critères correspond bien à celui attendu : en basant directement la planification sur la performance espérée de la classification, à la fois les similarités intrinsèques entre les objets et les imperfections des modèles sont prises en compte. La mesure d'entropie est superflue car elle ne capture que les similarités intrinsèques.

Les performances cumulées pour chaque classe montrent cependant des comportements variés. Bien qu'en moyenne le critère max-adaptatif offre une performance maximale supérieure à la planification aléatoire ainsi qu'une vitesse de convergence plus rapide, certaines classes ne sont pas ou peu reconnues. Dans le cas de $\omega = 7$, la performance du classifieur est plus faible qu'une classification aléatoire. Cela peut s'expliquer par un biais trop important du classifieur (visible par la matrice de confusion, figure 4.1) que la planification adaptative ne peut compenser. Cependant, la matrice de confusion obtenue après la planification adaptative (figure 4.16, droite) montre que le taux d'erreur est plus faible,




FIGURE 4.17 – Exemple de reconnaissance active avec le critère de planification max-adaptatif ($\alpha = 1$); à gauche : cartes de planification et points de vue sélectionnés; à droite. observations correspondantes. Le critère adaptatif permet la sélection en ligne de la carte de planification. La première observation est choisie aléatoirement.

au bénéfice du rejet et d'une augmentation des performances globales. Le rejet est souvent préférable (mieux vaut ne pas prendre de décision qu'une mauvaise décision). Cette difficulté de reconnaissance pour la base considérée est très liée à la nature des objets dont les apparences sont très proches. De telles ressemblances entre les objets de la base n'ont pas été envisagées dans les travaux précédents, notamment ceux de [Arbel et Ferrie, 2001] (notons toutefois la présence de plusieurs classes de véhicules dans [Borotschnig et al., 2000]). L'utilisation des bases de données existantes permettrait une comparaison supplémentaire entre l'entropie et le critère adaptatif.

Un autre aspect remarquable de la planification adaptative est son gain non constant avec la longueur de la séquence d'observation. En particulier, lorsque t augmente, la performance converge plus rapidement que le taux de rejet. Au delà de $t = 10$, des observations supplémentaires ne permettent plus d'augmenter sensiblement la performance de reconnaissance, alors que le taux de rejet, lui, diminue, ce qui entraîne une augmentation de l'erreur de classification. Ce phénomène peut s'expliquer en partie par l'aspect "myope" de la planification. Le critère ne tient compte que de la récompense immédiate (au bout d'une seule observation) pour évaluer le choix des CPDV, sans considérer un horizon de planification plus lointain. Pourtant, une récompense immédiate optimale est susceptible de conduire à une récompense globale sous optimale.

Enfin, la stratégie de planification adoptée, qui consiste à sélectionner les CPDV de manière à valider l'hypothèse courante, s'apparente à une stratégie de filtrage conservatif [Herbin, 1997] permettant de limiter l'erreur de classification. Un filtrage sélectif, permettant de contrôler le rejet des hypothèses peu probables, n'a pas été considéré. Une première approche consisterait par exemple à sélectionner les prochaines CPDV de manière à infirmer l'hypothèse courante la moins probable pour la rejeter définitivement avec une confiance élevée. Une approche similaire de filtrage de classes est abordée au chapitre 6.

CONCLUSION DU CHAPITRE

Ce chapitre a présenté un nouveau critère de planification, appelé critère adaptatif (ainsi qu'une variante, le critère max-adaptatif), basé sur l'ambiguïté entre les classes. Alors que la planification par entropie est très répandue en reconnaissance active, nous avons montré

que cette mesure ne permettait pas de capturer les défauts de modélisation. Ces défauts, inhérents à la reconnaissance automatique, peuvent conduire à une mauvaise classification et diminuent les performances globales de reconnaissance. La contribution apportée permet de prendre en compte ces défauts dans l'apprentissage du critère de planification. L'optimisation de la pondération entre l'entropie et le terme d'adaptation aux modèles a été conduite empiriquement sur les modèles utilisés. Elle a montré que l'entropie était superflue, car le critère adaptatif permettait également de capturer les similarités intrinsèques entre les objets. Ce nouveau critère s'adapte à la fois aux modèles et à l'état courant de la connaissance et exploite plus efficacement l'information hors ligne et en ligne. Les performances de reconnaissance s'en trouvent améliorées. Cependant, des limitations demeurent. En particulier, la nécessité d'une exploration exhaustive de l'espace des CPDV pendant l'apprentissage de la planification peut s'avérer impossible en situation réelle. Une évaluation à plus long terme de l'utilité d'une observation (i.e. son influence sur le choix des futures observations) permettrait une meilleure planification. Ces deux points sont les objectifs du chapitre suivant.

RÉSUMÉ

<i>Positionnement</i>	<ul style="list-style-type: none"> · apprentissage de la politique de planification des CPDV pour la reconnaissance active. · le classifieur est imparfait à cause des similarités intrinsèques <i>et</i> à des défauts de modélisation.
<i>Contributions</i>	<ul style="list-style-type: none"> · définition d'un nouveau critère de sélection des CPDV capable de capturer à la fois les similarités intrinsèques et les défauts de modélisations. La politique de planification est obtenue par apprentissage à l'aide du résultat du classifieur. · Les performances de ce critère sont supérieures à l'entropie sur l'application considérée.
<i>Limitations</i>	<ul style="list-style-type: none"> · planification myope (seul le résultat espéré immédiat est considéré pour la sélection des CPDV). · parcours exhaustif de l'espace des CPDV pendant l'apprentissage.

PLANIFICATION AVEC UN BUDGET D'OBSERVATIONS LIMITÉ : UNE APPROCHE PAR KRIGEAGE

DANS le chapitre précédent, les critères de planification des CPDV définis pour la reconnaissance active ont permis de tenir compte d'un aspect réaliste lié à une modélisation imparfaite des objets. La stratégie d'apprentissage associée implique cependant le calcul de ces critères sur une grille dense dans l'espace des CPDV, et requiert typiquement plusieurs centaines d'observations dans un espace mono-dimensionnel, ce nombre croissant exponentiellement avec la dimension. Or, dans un cadre applicatif réaliste, l'acquisition d'une observation est coûteuse (en temps, en énergie) car elle requiert un déplacement physique de l'agent visuel. Le coût global d'apprentissage rend la stratégie précédente difficilement applicable. Par ailleurs, seule une planification myope a été considérée, synonyme de sous-optimalité. Dans ce chapitre, une stratégie d'apprentissage novatrice est proposée pour permettre une mise en œuvre lorsque le budget d'observations est limité. À partir d'un classifieur "boîte noire", l'approche consiste en un couplage entre l'apprentissage par renforcement (section 5.2) et les techniques d'échantillonnage par krigeage (section 5.4). Cette combinaison d'outils permet de considérer un échantillonnage actif dans un espace de CPDV, donc nécessitant moins d'observations et sans discrétisation des espaces de recherche. L'apprentissage par renforcement, à travers le Q -learning et la programmation dynamique, offre de plus une estimation de l'utilité des CPDV à plus long terme permettant une planification non myope plus efficace. Les résultats expérimentaux obtenus sur la base de données de véhicules considérée au chapitre 3, ainsi qu'une comparaison avec les techniques classiques en Q -learning et en programmation dynamique sont présentés.

PLAN DU CHAPITRE

Ce chapitre est organisé de la manière suivante. Le contexte de l'apprentissage par renforcement et son application pour l'apprentissage de la planification des CPDV sont décrits à la section 5.1. Le formalisme de l'apprentissage par renforcement est défini à la section 5.2. Les méthodes *Q*-learning et programmation dynamique considérées dans ce chapitre, ainsi que les techniques classiques de résolution associées sont présentées à la section 5.3. Les processus gaussiens (PG), théorie sous-jacente au krigeage et à l'optimisation bayésienne, sont introduits à la section 5.4. Leur couplage avec le *Q*-learning et la programmation dynamique sont ensuite décrits. Cette nouvelle approche pour un apprentissage actif de la planification des CPDV est évaluée à la section 5.4 à la fois pour le *Q*-learning et pour la programmation dynamique (section 5.3.2). L'interprétation et les discussions des résultats obtenus sont reportées à la section 5.6.

5.1 INTRODUCTION

L'apprentissage par renforcement [Sutton et Barto, 1998] décrit une famille de problèmes dans lesquels un agent (indifféremment appelé système de décision ou acteur) doit apprendre de manière autonome à atteindre un objectif établi à l'avance. Par des interactions avec un critique (i.e. son environnement), l'agent apprend en accumulant de l'expérience et l'utilise pour améliorer son comportement face aux situations futures. Ce processus d'apprentissage à partir d'interactions avec l'environnement reflète la plupart des comportements animal et humain. Chaque action peut conduire à de bonnes ou mauvaises conséquences, immédiates ou futures. En accumulant cette expérience de causes à effets, il est possible d'agir de manière à atteindre une performance future espérée maximale. Résoudre un problème d'apprentissage par renforcement consiste pour l'agent à choisir, parmi un ensemble de possibilités, et étant donné son état de connaissance actuel, la prochaine action dans le but de maximiser une récompense espérée donnée par le critique (la récompense espérée étant connue à partir de l'expérience apprise). Ce cadre permet un apprentissage autonome de la politique de comportement. De nombreux travaux ont été réalisés pour tenter de poser les bases mathématiques de l'apprentissage par renforcement et d'élaborer des architectures de commandes. [Bellman, 1957] fait figure de pionnier. Plus récemment, des applications robotiques ont été réalisées telles que des robots footballeurs [Riedmiller et al., 2009], des bras manipulateurs [Althoefer et al., 2001; Peters et Schaal, 2008]. D'autres domaines sont également concernés comme les jeux [Tesauro, 1995] ou les problèmes d'ordonnancement [Gabel et Riedmiller, 2007]. Ce cadre d'apprentissage autonome est ici utilisé dans le problème de reconnaissance active considéré dans cette thèse, plus précisément pour l'apprentissage de la politique de planification des CPDV.

Un problème central en apprentissage par renforcement est le compromis entre l'exploration et l'exploitation. Pendant l'apprentissage, l'agent doit mettre à profit son expérience accumulée pour effectuer des actions qui se sont révélées utiles précédemment, mais acquérir de l'expérience requiert une exploration parmi les actions non testées [Sutton et Barto, 1998]. Ce compromis est étroitement lié à la notion d'efficacité en données [Atkeson et Santamaria, 1997], c'est-à-dire le nombre d'interactions nécessaires pour atteindre les performances requises. Lorsque ces interactions sont coûteuses (en temps, en énergie), l'efficacité en données est primordiale. Des solutions limitant le nombre d'interactions reposent le plus souvent sur une modélisation de la dynamique de l'environnement, comme le contrôle optimal [Murray-Smith et Sbarbaro, 2002]. Cette connaissance a priori permet de prédire la récompense et ainsi de réduire le nombre d'interactions nécessaires. Cependant, une telle modélisation peut s'avérer inefficace pour des systèmes plus complexes [Atkeson et Schaal, 1997].

Dans ce chapitre, deux techniques populaires d'apprentissage par renforcement, le *Q*-

learning et la programmation dynamique, sont considérées. Elles font partie des techniques dites sans modèle. L'apprentissage par renforcement sans modèle est une alternative avantageuse lorsque la complexité de la tâche est élevée (i.e. la dynamique de l'environnement est inconnue), ce qui est le cas en reconnaissance active. L'approche consiste à estimer la politique d'actions exclusivement à partir d'interactions avec l'environnement, en chaque état rencontré, et sans utiliser de modèle de prédiction de la récompense. L'apprentissage par renforcement sans modèle est cependant, dans son approche de base, bien moins efficace en données et beaucoup plus sensible au fléau de la dimension, car l'espace d'exploration croît exponentiellement avec l'horizon de planification [Bellman, 1961].

L'objectif de ce chapitre est de proposer des algorithmes efficaces en données pour traiter des problèmes dans lesquels les interactions sont coûteuses en temps et en énergie et par conséquent limitées. La plupart des solutions pour le Q -learning et la programmation dynamique sont inapplicables sans relâcher la complexité initiale de ces problèmes, et conduisent, le cas échéant, à une représentation très simplifiée. Des hypothèses sur les actions plausibles sont émises par [Boone, 2002] pour réduire l'espace d'état et d'actions, tandis qu'une planification myope (i.e. ne considérant que la récompense immédiate) a été considérée par [Dearden et al., 1998; Lizotte et al., 2007].

L'apprentissage de la planification des CPDV pour la reconnaissance active est ici décrit comme un problème d'apprentissage par renforcement. Le problème de la reconnaissance active a été décrit au chapitre 2. L'agent autonome évolue dans un environnement inconnu et a pour objectif de collecter les observations les plus utiles à la reconnaissance. L'acquisition de ces observations est gouvernée par une politique de planification, cette dernière étant obtenue par la résolution du problème d'apprentissage par renforcement. Elle doit permettre de guider l'agent dans l'espace des CPDV là où cette information utile est supposée être. La recherche d'une politique de planification requiert l'estimation de fonctions non linéaires, non différentiables, continues et de dimension pouvant être grande. Ces contraintes, indissociables d'un cadre applicatif réel, sont au centre de ce chapitre.

Les principales approches pour résoudre le problème de planification des CPDV en reconnaissance active ont été décrites au chapitre 4. Elles incluent un calcul hors ligne d'une politique de planification basée sur un critère d'ambiguïté entre les classes comme l'entropie [Callari et Ferrie, 1996b; Borotschnig et al., 2000; Arbel et Ferrie, 2001; Schiele et Crowley, 2002] ou des métriques dans l'espace de représentation [Kovacic et al., 1998; Laporte et al., 2004]. Des approches par apprentissage par renforcement ont également été proposées par [Deinzer et al., 2000; Paletta et Pinz, 2000; Derichs et al., 2005]. Elles reposent sur une estimation stochastique (par Monte Carlo) de la récompense. Dans [Derichs et al., 2005] la notion de coût d'acquisition est considérée et intégrée dans le critère d'utilité des CPDV pour une reconnaissance active avec une dépense énergétique minimale. À notre connaissance cependant, le coût d'apprentissage de la politique de planification n'est considéré dans aucune des approches existantes. Les budgets d'observations d'apprentissage sont très supérieurs à ceux envisagés ici, ce qui rend ces méthodes inadaptées.

La reconnaissance active implique des espaces d'états et d'actions continus. Leur discrétisation est couramment considérée pour la résolution du problème. Cela a très tôt été suggéré par [Bellman, 1961] pour des applications temps réel n'ayant parfois pas de solutions analytiques (voir aussi [Leung et al., 2005; Singh et al., 2007]). Cependant, une discrétisation fine est requise pour atteindre des performances acceptables, et la complexité reste importante lorsque la dimension du problème est élevée. Une autre stratégie courante est de considérer une fonction d'interpolation permettant une prédiction quelle que soit la valeur (continue) des variables. Plusieurs familles de fonctions d'interpolation ont été suggérées, notamment par [Sutton et Barto, 1998; Bertsekas et Tsitsiklis, 1996; Powell, 2007]. Cependant, la fiabilité de la prédiction en un point repose toujours sur la quantité de mesures disponibles au voisinage de celui-ci. L'interpolation est de plus délicate en grande dimension [Bellman, 1961]. Pour résoudre le problème de reconnaissance active, il serait préférable de rester dans des espaces continus tout en considérant un budget de mesures

restreint.

Les processus gaussiens (PG) [Jones, 2001; Rasmussen et Williams, 2006] sont particulièrement adaptés à ce contexte. Les techniques d'échantillonnage actifs, qui en découlent, notamment l'optimisation bayésienne et la prédiction par krigeage, offrent des outils d'analyse de fonctions continues pouvant être complexes.

L'introduction des PG en apprentissage par renforcement a été proposée par [Strens, 2000; Dearden et al., 1999] pour la modélisation du système en inférant une distribution de probabilité à partir d'un espace continu de fonctions. Dans [Engel et al., 2005; Deisenroth et al., 2009], une approximation de la fonction de valeur a été effectuée à l'aide de PG. L'optimisation bayésienne et l'échantillonnage actif se sont révélés efficaces dans plusieurs autres applications de l'apprentissage par renforcement [Lizotte et al., 2007; Brochu et al., 2009; Martinez-Cantin et al., 2009]. Cependant, dans les travaux précédents, le potentiel des PG n'est pas exploité au maximum car ils sont utilisés seulement pour l'une des deux étapes (l'optimisation bayésienne ou l'interpolation). Nous proposons ici d'utiliser les GP pour traiter simultanément les deux étapes. Le formalisme de l'apprentissage par renforcement ainsi que la définition des fonctions de valeur et de la politique de planification font l'objet de la section suivante.

5.2 FORMULATION DU PROBLÈME

5.2.1 Apprentissage par renforcement

Le bouclage entre action et perception tel qu'il intervient en apprentissage par renforcement est représenté à la figure 5.1. L'agent interagit à des pas de temps discrets t en effectuant des actions a_t , chacune d'entre elles conduisant à une récompense $r_{t+1} \in \mathcal{D}_r$, où \mathcal{D}_r est l'espace des récompenses ($\mathcal{D}_r = \mathbb{R}$ généralement). Une action aboutit à un nouvel état s_{t+1} . Un problème d'apprentissage par renforcement est conventionnellement modélisé par un processus de décision markovien (PDM). Un PDM est défini par un tuple $\{\mathcal{S}, \mathcal{A}, p(\cdot | s, a), q(\cdot | s, a, s')\}$ où \mathcal{S} et \mathcal{A} sont respectivement les espaces d'état et d'action du système. Étant donné un état $s \in \mathcal{S}$ rencontré par l'agent, celui-ci peut choisir une action dans le sous-ensemble $\mathcal{A}(s)$ des actions possibles pour s , tel que $\bigcup_{s \in \mathcal{S}} \mathcal{A}(s) = \mathcal{A}$. La fonction de transition $p(\cdot | s, a)$ représente la distribution de probabilité sur l'espace des états futurs possibles, étant donné l'état courant s et l'action a effectuée. Le terme $q(\cdot | s, a, s')$ est une distribution sur la valeur de la récompense élémentaire lorsque, de l'état initial s , l'action a est effectuée et conduit à l'état futur s' . Ces deux distributions définissent complètement la dynamique du PDM. Une hypothèse usuelle consiste à considérer les espaces \mathcal{S} et \mathcal{A} stationnaires, ce qui revient à supposer que le processus d'apprentissage est invariant par décalage temporel. Notons également que nous nous plaçons ici dans le cas général des PDM infinis, c'est-à-dire que les distributions $p(\cdot | s, a)$ et $q(\cdot | s, a, s')$ sont continues. Dans l'approche sans modèle considérée, $p(\cdot | s, a)$ est supposée inconnue.

Étant donné un état présent s , une action a et un état futur s' associé tel que $s \xrightarrow{a} s'$, la récompense espérée relativement à $q(\cdot | s, a, s')$ est donnée par :

$$r(s, a, s') = \mathbb{E}_q[r_{t+1} | s_t = s, a_t = a, s_{t+1} = s'] = \int_{\mathcal{D}_r} r_{t+1} q(r_{t+1} | s, a, s') dr_{t+1} \quad (5.1)$$

L'état futur s' étant issu de $p(\cdot | s, a)$, la récompense espérée finale $r(s, a)$ est donnée par :

$$r(s, a) = \mathbb{E}_p[r(s, a, s') | s_t = s, a_t = a] = \int_{\mathcal{S}} r(s, a, s') p(s' | s, a) ds' \quad (5.2)$$

La stochasticité de r , due à la fois à l'incertitude sur la valeur de la récompense et à l'incertitude sur l'état futur, est aussi appelée stochasticité intrinsèque du PDM [Engel et al., 2005]. Pour des lectures plus complètes sur la théorie des PDM, se référer à [Sutton et Barto, 1998; Bertsekas, 2005; Whitehead et Ballard, 1991].




FIGURE 5.1 – Boucle d’interaction entre l’agent et son environnement en apprentissage par renforcement.

Une politique de planification stationnaire $\Pi(\cdot)$ est définie par une règle de décision de la prochaine action. Elle est basée sur l’état présent du système qui résume l’historique des actions effectuées et des états précédemment rencontrés. Étant donnée une politique $\Pi(\cdot)$, la valeur associée à un état s est égale à la récompense cumulée espérée de la séquence d’actions prescrite par $\Pi(\cdot)$ à partir de s . Cela conduit à la définition de la *fonction de valeur d’un état* :

$$V^{\Pi(\cdot)}(s) = \mathbb{E} \left[\sum_{t=0}^H \gamma^k r(s_t, a_t) \mid s_0 = s \right], \text{ et } a_t = \Pi(s_t) \quad (5.3)$$

où le paramètre $\gamma \in [0, 1]$ est un facteur d’oubli permettant de donner moins d’importance aux actions les plus lointaines de l’horizon de planification H , et $H = \infty$ dans le cas général. $V(\cdot)$ peut elle-même être une variable aléatoire (la stochasticité de $V(\cdot)$ est dans ce cas appelée stochasticité extrinsèque [Engel et al., 2005]), c’est pourquoi sa valeur espérée est considérée dans l’équation (5.3). Cette équation peut être reformulée récursivement :

$$V^{\Pi(\cdot)}(s) = \mathbb{E} \left[r(s_t, a_t) + \gamma V^{\Pi(\cdot)}(s_{t+1}) \mid s_t = s, a_t = \Pi(s_t) \right] \quad (5.4)$$

De même que pour l’état, une valeur peut être associée à une action a prise étant donné l’état courant s et poursuivant ensuite la politique $\Pi(\cdot)$. Cela conduit à la définition de la *fonction de valeur d’une action* :

$$Q_s^{\Pi(\cdot)}(a) = \mathbb{E} \left[r(s_t, a_t) + \gamma V^{\Pi(\cdot)}(s_{t+1}) \mid s_t = s, a_t = a \right] \quad (5.5)$$

Résoudre un problème d’apprentissage par renforcement revient à déterminer la politique optimale $\Pi^*(\cdot)$ qui fournit la séquence d’actions maximisant la récompense cumulée espérée quel que soit l’état initial s . Cette récompense correspond à la valeur maximale de $V(\cdot)$ sur \mathcal{S} , et est notée $V^*(s)$. $V^*(\cdot)$ satisfait l’équation d’optimalité de Bellman pour $V(\cdot)$:

$$V^*(s) = \max_{a \in \mathcal{A}(s)} \mathbb{E} \left[r(s_t, a_t) + \gamma V^*(s_{t+1}) \mid s_t = s, a_t = a \right] \quad (5.6)$$

Avec l’équivalence

$$V^*(s) = \max_{a \in \mathcal{A}(s)} Q_s^*(a) \quad (5.7)$$

la fonction de valeur maximale d’action, $Q_s^*(\cdot)$, satisfait l’équation d’optimalité de Bellman pour $Q_s(\cdot)$:

$$Q_s^*(a) = \mathbb{E} \left[r(s_t, a_t) + \gamma \max_{a' \in \mathcal{A}(s)} Q_{s_{t+1}}^*(a') \mid s_t = s, a_t = a \right] \quad (5.8)$$

Dans la suite, une estimation indirecte¹ de la politique optimale est envisagée. Le principe vise à estimer les fonctions de valeur $V^*(\cdot)$ ou $Q_s^*(\cdot)$ en résolvant les équations de Bellman (5.7) et (5.8), puis à déduire $\Pi(\cdot)$. Cette approche est parfois appelée *critic-only* par opposition à l’approche *actor-only* précédente [Konda et Tsitsiklis, 2003]. L’estimation indirecte est particulièrement adaptée aux politiques déterministes telles que celles considérées.

1. Les termes d’*approche directe vs. approche indirecte* sont parfois utilisés pour différencier les méthodes d’apprentissage par renforcement *basée modèle vs. sans modèle* [Sutton et Barto, 1998]. Ici, ils sont exclusivement réservés pour différencier *estimation de $\Pi(\cdot)$ vs. estimation des fonctions de valeur*.

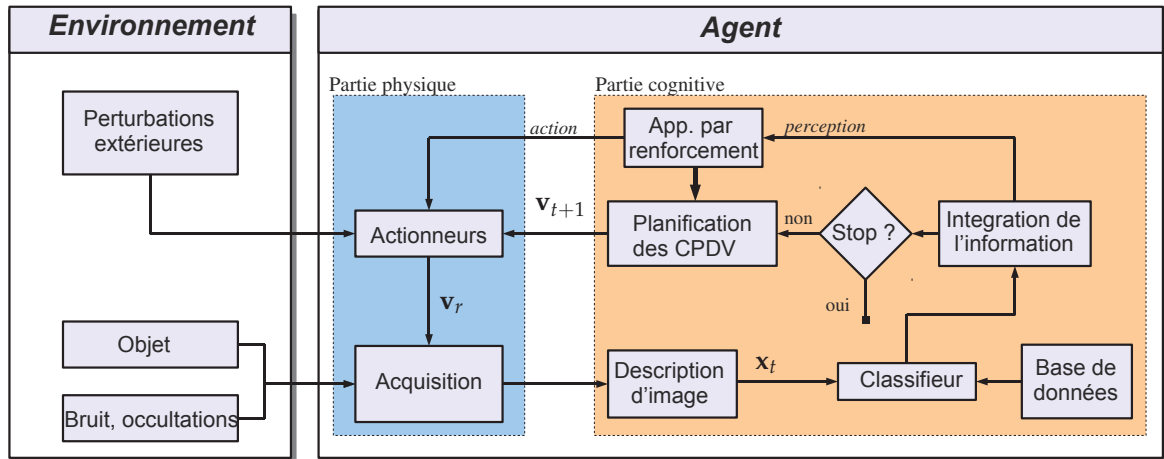


FIGURE 5.2 – Boucle fermée de reconnaissance active entre le système de décision (l'agent) et son environnement et avec apprentissage par renforcement de la politique de planification.

L'estimation indirecte a été utilisée dans une large variété d'applications en apprentissage par renforcement, notamment à travers le Q -learning [Dearden et al., 1998; Martín et al., 2010] et la programmation dynamique [Riedmiller et al., 2009; Ormonet et Sen, 2002]. Ces deux techniques sont abordées respectivement aux sections 5.3.1 et 5.3.2.

5.2.2 Application de l'apprentissage par renforcement pour la planification des CPDV

La formulation de l'apprentissage par renforcement définie précédemment est ici appliquée au problème de l'apprentissage de la politique de planification des CPDV en reconnaissance active. Dans ce contexte, l'agent a la capacité d'explorer l'espace d'observations, permettant une information visuelle plus riche. La performance de reconnaissance s'en trouve améliorée en choisissant la séquence d'actions (i.e. de CPDV) conduisant à l'acquisition des observations les plus informatives. Cette séquence informative doit être planifiée à l'aide de la politique apprise.

Définition du PDM pour la planification des CPDV

Le formalisme adopté pour une reconnaissance active a été présenté au chapitre 2. Il est rappelé brièvement dans ce paragraphe et est utilisé pour la définition des éléments constitutifs du PDM. L'ensemble des classes considérées est noté $\Omega = \{1, \dots, \mathcal{K}\}$. En reconnaissance active, une séquence de T observations $\mathbf{X}_T = \{x_1, \dots, x_T\}$ est acquise, telle que $x_t \in \mathcal{X} = \mathbb{R}^d$ (\mathcal{X} étant l'espace d'observation). Les observations sont associées à leur CPDV respectives $\mathbf{V}_T = \{v_1, \dots, v_T\}$ telles que $v_t \in \mathcal{V} = \mathbb{R}^v$ (\mathcal{V} étant l'espace des CPDV). Cette séquence d'observations est utilisée pour classifier l'objet. La classe $\omega^* \in \Omega$ dénote la vraie classe de l'objet. Le schéma d'action-décision séquentiel impliqué en reconnaissance active, muni de l'apprentissage par renforcement de la politique de planification, est illustré par la figure 5.2.

Au pas de temps t , l'état du système, noté s_t , contient :

- l'hypothèse actuelle sur la classe de l'objet, ω_t .
- l'information accumulée depuis le début du processus, représentée par la distribution $P(\omega | \mathbf{X}_t, \mathbf{V}_t)$.
- les CPDV déjà visités, \mathbf{V}_t .

Nous avons donc :

$$s_t = \{\omega_t, P(\omega | \mathbf{X}_t, \mathbf{V}_t), \mathbf{V}_t\} \quad (5.9)$$

L'espace d'action $\mathbb{A}(s_t)$ contient l'ensemble des actions possibles pouvant être choisies dans l'état s_t . Il est défini à partir de l'espace des CPDV \mathcal{V} . Une action a_t est donnée par

$$a_t = v_{t+1}, \quad v_{t+1} \in \mathcal{V} = \mathbb{R}^v \quad (5.10)$$

Chaque CPDV n'étant visitée qu'une seule fois au cours de la reconnaissance, les $t - 1$ CPDV déjà visités sont exclus de $\mathbb{A}(s_t)$.

La connaissance de l'état (5.9) nécessite le calcul de la probabilité a posteriori $P(\omega | \mathbf{X}_t, \mathbf{V}_t)$. Celle-ci est obtenue par les équations (2.10) et (2.11) qui définissent le schéma d'intégration séquentiel de l'information. L'équation (2.10) fait en particulier apparaître l'hypothèse markovienne dans la mise à jour de l'état de connaissance du système, car l'état courant est obtenu à partir de l'état précédent. Le classifieur élémentaire intervenant dans ce schéma est issu de la vraisemblance $P(x_{t+1} | v_{t+1}, \omega)$. Il est indépendant de la politique de sélection des CPDV et est considéré dans ce chapitre comme une "boîte noire". L'apprentissage de la politique de planification des CPDV, qui est représentée dans ce schéma d'intégration par la distribution (2.13), nécessite encore la définition de la récompense élémentaire r , abordée ci-après.

Définition de l'optimalité de la politique de planification et récompense associée

L'optimalité de la politique de planification doit prendre en compte deux points essentiels : (i) la longueur de la séquence d'observation, T , doit être la plus faible possible pour atteindre le niveau de confiance requis ; (ii) étant donné un nombre t d'observations, celles-ci doivent être choisies de manière à maximiser la confiance en l'inférence. Cette optimalité est quantifiée à l'aide des critères $Perf_{\max}$, T_{moy} et $Aire_T$ définis à la section 2.4.3. Chaque action étant associée à une récompense, cette dernière doit refléter l'optimalité définie. La quantification de l'utilité des CPDV pour la reconnaissance a été abordée au chapitre 4, conduisant à la définition des critères adaptatif et max-adaptatif. Ici, une version simplifiée du critère max-adaptatif (4.6) est adoptée. Le calcul de l'espérance qui apparaît dans le critère original n'intervient plus ici, car une seule observation est disponible après chaque action. La récompense est définie par :

$$r_t = P(\omega^* | \mathbf{X}_t, \mathbf{V}_t) - \max_{\omega \in \Omega, \omega \neq \omega^*} P(\omega | \mathbf{X}_t, \mathbf{V}_t) \quad (5.11)$$

Par cette définition, la récompense est d'autant plus grande que l'écart entre le MAP (en dehors de ω^*) et la probabilité a posteriori de la vraie classe est grand, ce qui revient à lever l'ambiguïté d'interprétation.

Dans la suite, la stochasticité de r est supposée dépendre uniquement de la distribution $p(\cdot | s, a)$. Cette probabilité de transition de l'état courant vers l'état futur est obtenue à partir de l'incertitude sur le placement de l'agent aux CPDV prescrites par la politique. Ce modèle d'incertitude sur les CPDV se traduit par un modèle d'incertitude (inconnu) sur l'état futur du système. L'espérance relativement à $p(\cdot | s, a)$ qui intervient dans le calcul de $r(s, a)$ (équation (5.2)) peut être calculée en considérant plusieurs réalisations de l'action a et en calculant la valeur moyenne des récompenses obtenues. Dans les expérimentations, cette espérance a été calculée à partir de dix réalisations des actions planifiées. Par cette définition de r (équation 5.11), la politique de planification des CPDV doit permettre, à partir de l'hypothèse actuelle ω_t , de sélectionner les prochaines CPDV de manière à confirmer cette hypothèse, i.e. en maximisant r_t avec $\omega^* = \omega_t$. L'apprentissage de la politique de planification fait l'objet de la section suivante.

5.3 DÉTERMINATION DE LA POLITIQUE OPTIMALE : MÉTHODES DE RÉFÉRENCE

Le problème d'apprentissage par renforcement pour la planification des CPDV étant posé, sa formulation par Q-learning et par programmation dynamique est abordée dans

cette section. Les approches classiques de résolution, mises en œuvre dans les expérimentations pour une comparaison avec les algorithmes proposés, sont également décrites.

5.3.1 Q-learning

Le Q-learning [Watkins et Dayan, 1992] fait partie de la famille des méthodes de résolution par différence temporelle. La fonction $Q_s(\cdot)$, qui associe une valeur à une action prise à partir de l'état courant, est centrale dans cette approche. L'apprentissage de la fonction $Q_s(\cdot)$ optimale, notée $Q_s^*(\cdot)$, proposée par le Q-learning, est récursif. Chaque mise à jour est effectuée à partir de la valeur précédente et des interactions avec l'environnement. Dans son implémentation classique, la règle de mise à jour est donnée à chaque pas de temps par la récursion :

$$Q_{s_t}(a_t) \leftarrow Q_{s_t}(a_t) + \alpha \left[r(s_t, a_t) + \gamma \max_{a_{t+1} \in \mathbb{A}(s_t)} Q_{s_{t+1}}(a_{t+1}) - Q_{s_t}(a_t) \right] \quad (5.12)$$

où le paramètre $\alpha \in [0, 1]$ détermine l'influence de la valeur précédente de $Q_{s_t}(a_t)$ dans sa mise à jour. Pour l'application considérée, l'apprentissage de $Q_s(\cdot)$ prend en compte les considérations suivantes :

- La tâche est supposée épisodique, i.e., chaque trajectoire planifiée est constituée d'un nombre H fini d'actions, H étant l'horizon de planification. Cette hypothèse est justifiée par le fait que la reconnaissance est effectuée à partir d'une séquence finie d'observations. De surcroît, pour un facteur d'oubli $\gamma < 1$, l'influence des actions lointaines devient négligeable devant les actions plus immédiates.
- L'apprentissage de $Q_s(\cdot)$ (équation (5.12)) est associé à un historique d'éligibilité² [Sutton et Barto, 1998]. La mise à jour est effectuée seulement après les H actions et la récompense cumulée associée.
- La fonction $Q_s(\cdot)$ doit être connue quelque soit l'état s du PDM. Cependant en pratique, seule la valeur des actions à partir de l'hypothèse actuelle ω_t (que l'agent doit tenter de discriminer en maximisant la récompense espérée) est nécessaire à Q . (les actions déjà effectuées sont prise en compte en étant exclues de $\mathbb{A}(s_t)$) Pendant l'apprentissage, chaque modèle de la base de donnée est considéré, et ω_t est remplacé par ω^* . Ainsi, nous noterons dans la suite $Q_s(\cdot) = Q_{\omega^*}(\cdot)$.

L'équation 5.12 devient alors

$$Q_{\omega^*}(a_t) \leftarrow Q_{\omega^*}(a_t) + \alpha \left[r(s_t, a_t) + \gamma \max_{\substack{a_{t+1}, \dots, \\ a_{t+H-1} \in \\ \mathbb{A}(s_{t+1}) \times \dots \\ \times \mathbb{A}(s_{t+H-1})}} \sum_{k=t+1}^{t+H} \gamma^{k-t-1} r(s_k, a_k) - Q_{\omega^*}(a_t) \right] \quad (5.13)$$

Par commodité, la récompense espérée de la séquence d'actions suivant a_t intervenant dans (5.13) est définie comme une fonction de H actions $\mathbf{a}_H = (a_{t+1}, \dots, a_{t+H})$:

$$R(\mathbf{a}_H) = \sum_{k=t+1}^{t+H} \gamma^{k-t-1} r(s_k, a_k) \quad (5.14)$$

La mise à jour de $Q_{\omega^*}(\cdot)$ par (5.13) est réalisée jusqu'à sa convergence vers la fonction optimale $Q_{\omega^*}(\cdot)$.

Itération de la politique

Une méthode usuelle d'exploration de l'espace des actions pour estimer $Q_{\omega^*}(\cdot)$, adoptée ici comme référence, est la méthode d'itération de la politique. Elle consiste à estimer

2. Eligibility trace.

Algorithme 3: Q -learning : implémentation de référence considérée

Entrées : $budget_{INTERP}$, $budget_{OPT}$
 ω^* , γ , α , L , H , tol
 $Q_{\omega^*}^{(0)}(\cdot)$ défini arbitrairement

Sorties : politique de planification optimale $\Pi_{\omega^*}^*(\cdot)$

- 1 $\mathbf{X}_0 = \emptyset$; $\mathbf{V}_0 = \emptyset$;
- 2 $s_0 \leftarrow \{\omega^*, P(\omega \mid \mathbf{X}_0, \mathbf{V}_0) \text{ uniforme}, \mathbf{V}_0\}$;
- 3 extraire $\Pi_{\omega^*}^{(0)}(\cdot)$ de $Q_{\omega^*}^{(0)}(\cdot)$ (éq. (5.15));
- 4 **pour** chaque épisode $l = 0, \dots, L - 1$ **faire**
- 5 **répéter**
- 6 $t \leftarrow 0$; $s \leftarrow s_0$;
- 7 $a_t \leftarrow \epsilon\text{-greedy}(\Pi_{\omega^*}^{(l)}(s_t))$;
- 8 calculer $R^{max} = \max_{\mathbf{a}_H} R(\mathbf{a}_H)$ (éq. (5.14)) à l'aide de $budget_{OPT}$ échantillons
- 9 avec $\mathbf{a}_H = (a_{t+1}, \dots, a_{t+H})$ obtenu par la politique ϵ -greedy courante
- 10 tel que $[a_{t+k} - tol, a_{t+k} + tol] \cap \mathbf{V}_{t+k} = \emptyset, k = 1, \dots, H$;
- 11 mettre à jour $Q_{\omega^*}^{(l)}(a_t)$ (éq. (5.13)) et obtenir $Q_{\omega^*}^{(l+1)}(a_t)$;
- 12 **jusqu'à** $budget_{INTERP}$ épuisé;
- 13 obtenir $\widehat{Q}_{\omega^*}^{(l+1)}(a_t)$ par interpolation (éq. 5.16);
- 14 extraire $\Pi_{\omega^*}^{(l+1)}(\cdot)$ à partir de $\widehat{Q}_{\omega^*}^{(l+1)}(\cdot)$ (éq. (5.15));
- 15 $\Pi_{\omega^*}^*(\cdot) = \Pi_{\omega^*}^{(L)}(\cdot)$;

conjointement $Q_{\omega^*}^*(\cdot)$ et la politique de planification associée, $\Pi_{\omega^*}^*(\cdot)$ à travers une série d'épisodes. À chaque épisode l , l'espace d'actions est exploré à l'aide de la politique (sous-optimale) courante $\Pi_{\omega^*}^{(l)}(\cdot)$, et $Q_{\omega^*}^{(l)}(\cdot)$ est mis à jour à l'aide de (5.13). Après chaque épisode, la politique est mise à jour en maximisant $Q_{\omega^*}^{(l+1)}(\cdot)$ sur l'espace des actions :

$$\Pi_{\omega^*}^{(l+1)}(s) = \operatorname{argmax}_{a \in \mathbf{A}(s)} Q_{\omega^*}^{(l+1)}(a) \quad (5.15)$$

En pratique, l'exploration de l'espace des actions requiert également des actions aléatoires pour éviter les optima locaux. La proportion d'aléatoire est gouvernée par un paramètre ϵ , conduisant à une politique de recherche ϵ -greedy (se référer à [Sutton et Barto, 1998] pour une description détaillée de cette méthode).

La figure 5.3 illustre la procédure de mise à jour par l'équation (5.13) pour $H = 2$. Les principales étapes impliquées de la méthode de référence adoptée en Q -learning sont résumées par l'algorithme 3. Le paramètre tol a pour rôle d'exclure un voisinage autour des CPDV déjà visitées. Un budget de $budget_{INTERP}$ actions a_t est défini pour chaque épisode. Ce budget se réfère au nombre de points à partir desquels la fonction $Q_{\omega^*}(\cdot)$ est interpolée. Ce budget doit être aussi faible que possible pour assurer une bonne efficacité en données, tout en étant suffisant puisqu'il conditionne directement la qualité de l'interpolation (cf. figure 5.3, gauche) À la ligne 8, une maximisation de la récompense espérée est requise. Celle-ci peut être effectuée à l'aide d'une stratégie de recherche quelconque, indépendamment de la politique de planification recherchée. On parle dans ce cas de méthode par différence temporelle sans politique³ [Sutton et Barto, 1998]. Un budget de $budget_{OPT}$ trajectoires \mathbf{a}_H est consacré à cette maximisation. De même que $budget_{INTERP}$, $budget_{OPT}$ doit être le plus faible possible tout en étant suffisant pour une estimation correcte du maximum global (cf. figure 5.3, droite). L'approche usuelle consiste en une maximisation par une politique de recherche ϵ -greedy. Une série de $budget_{OPT}$ trajectoires est effectuée, et la

3. *Off-policy TD control.*

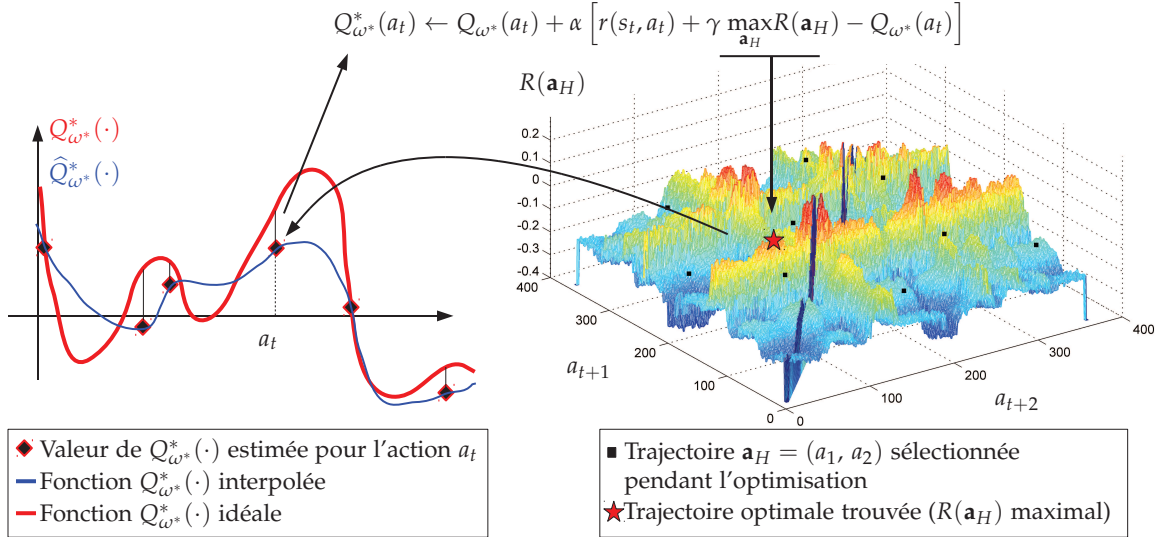


FIGURE 5.3 – Illustration de l'échantillonnage impliqué dans le Q-learning. Le calcul de $\hat{Q}_{\omega^*}^*(\cdot)$ requiert deux étapes principales : une optimisation globale (à droite) et une interpolation (à gauche).

récompense espérée maximale trouvée est prise comme estimateur.

À la fin de l'apprentissage, $Q_{\omega^*}^*(\cdot)$ n'est connue qu'en des valeurs discrètes dans l'espace des actions et un prédicteur continu $\hat{Q}_{\omega^*}^*(\cdot)$ est obtenu par interpolation. Un choix courant consiste en une interpolation par noyau [Deinzer et al., 2000] :

$$\hat{Q}_{\omega^*}^*(a) = \frac{\sum_{a'} k(a, a') Q_{\omega^*}^*(a')}{\sum_{a'} k(a, a')} \quad (5.16)$$

où le terme $k(a, a')$ est la mesure de distance (i.e. le noyau) entre les actions a et a' . Notons que la précision de cette méthode d'interpolation dépend fortement du nombre de mesures disponibles.

5.3.2 Programmation dynamique

Une autre technique de résolution d'un problème d'apprentissage par renforcement est basée sur la programmation dynamique [Bellman, 1961; Puterman, 1994; Bertsekas, 2005; Powell, 2007]. Celle-ci consiste en une procédure récursive qui utilise les fonctions de valeur à chaque pas de temps pour organiser la recherche de la politique optimale. La reconnaissance active mettant en œuvre une planification séquentielle, cette planification peut être formulée et résolue par programmation dynamique de manière analogue à la commande optimale. Cependant, une différence entre l'application considérée et la commande optimale, en plus des états continus, est que la fonction de transition $p(\cdot | s, a)$ est inconnue. Cette approche par programmation dynamique sans modèle est, à notre connaissance, pour la première fois mise en œuvre ici en reconnaissance active.

La programmation dynamique suit une approche différente du Q-learning. L'état final du système - la reconnaissance avec une probabilité 1 en un nombre d'observations minimal - est connu et dénoté s_T . La programmation dynamique consiste en une recherche itérative des T actions (a_{T-1}, \dots, a_0) qui permettent un passage de s_T vers un état initial s_0 (correspondant à une loi a posteriori uniforme sur la classe de l'objet) avec un coût minimal. Dans ce contexte, le coût élémentaire espéré d'une action a_t , étant donné l'état s_{t+1} , peut être défini par $-r(s_{t+1}, a_t)$ qui est l'opposé de la récompense espérée définie par l'équation (5.2). La valeur de s_{t+1} , $V^*(s_{t+1})$, est le coût minimal (relativement à $-r$) pour atteindre l'état final s_T à partir de s_{t+1} . Au pas de temps t , le coût minimal de l'action a_t est donné à l'aide de l'équation d'optimalité de Bellman (5.5) par :

$$Q_{s_{t+1}}^*(a_t) = \mathbb{E} [-r(s_{t+1}, a_t) + \gamma V^*(s_{t+1})] \quad (5.17)$$




FIGURE 5.4 – Procédure de récursion par programmation dynamique pour l'apprentissage de la politique optimale.

Algorithme 4: Récursion par programmation dynamique

Entrées : ω^* , V_{term} , γ , T , $\text{budget}_{\text{OPT}}$, tol

Sorties : politique de planification optimale $\Pi_{\omega^*}^*(\cdot)$ (séquence de T actions) après 1 épisode

- 1 $\mathbf{V}_0 = \emptyset$; $\mathbf{X}_0 = \emptyset$;
 - 2 $s_T \leftarrow \{\omega^*, P(\omega \mid \mathbf{V}_0, \mathbf{X}_0) = \mathbf{1}_{\{\omega=\omega^*\}}, \mathbf{V}_0\}$;
 - 3 $V^*(s_T) \leftarrow V_{\text{term}}$;
 - 4 **pour** $t = T - 1, \dots, 0$ **faire**
 - 5 calculer $\Pi_{\omega^*}^*(s_{t+1}) = \underset{a_t \in \mathbf{A}(s_{t+1})}{\text{argmin}} Q_{\omega^*}^*(a_t)$ à l'aide de $\text{budget}_{\text{OPT}}$ échantillons
 avec a_t obtenu par la politique ϵ -greedy courante
 tel que $[a_t - \text{tol}, a_t + \text{tol}] \cap \mathbf{V}_t = \emptyset$;
 et $Q_{\omega^*}^*(a_t) = \mathbb{E}[-r(s_{t+1}, a_t) + \gamma V^*(s_{t+1})]$
 - 6 effectuer $\Pi_{\omega^*}^*(s_{t+1})$; observer s_t ;
 - 7 $V^*(s_t) \leftarrow Q_{\omega^*}^*(\Pi_{\omega^*}^*(s_{t+1}))$;
-

Notons qu'ici encore seule une partie de l'état, ω^* , est nécessaire à Q pendant l'apprentissage. Par conséquent, nous pouvons également écrire $Q_{s_t}(\cdot) = Q_{\omega^*}(\cdot)$. Partant de s_T et d'un coût terminal V_{term} , l'équation d'optimalité de Bellman est résolue à chaque pas t dans le but de minimiser $V(s_{T-t})$. L'action correspondante est alors effectuée et la procédure est répétée à partir du nouvel état. À la fin de l'apprentissage, la politique optimale obtenue est utilisée à partir de $t = 0$ tel qu'illustré par la figure 5.4. La procédure d'estimation récursive est résumée par l'algorithme 4.

Contrairement au Q -learning, en programmation dynamique la connaissance exhaustive de la fonction $Q_{\omega^*}^*(\cdot)$ n'est pas nécessaire à la détermination de la politique. La planification est obtenue directement par la séquence des T actions résultantes apprises. En revanche, comme pour le Q -learning, l'approche par programmation dynamique est confrontée à des espaces de recherche continus. L'implémentation de référence utilisée en programmation dynamique sans modèle est basée sur une méthode d'itération de politique similaire à celle du Q -learning. À chaque itération, un budget de $\text{budget}_{\text{OPT}}$ actions est utilisé pour la recherche du minimum global de $Q_{\omega^*}^*(\cdot)$ (algorithme 4, ligne 5) par une politique ϵ -greedy [Sutton et Barto, 1998]. Chaque ensemble de T itérations est vu comme un épisode. La politique est mise à jour à la fin de chaque épisode, et la politique optimale est obtenue après une série de L épisodes.

Pour augmenter l'efficacité en données du Q -learning et de la programmation dynamique, les deux budgets impliqués $\text{budget}_{\text{INTERP}}$ et $\text{budget}_{\text{OPT}}$ devraient être utilisés dans

des politiques de recherche permettant une meilleure exploitation de l'expérience déjà acquise. Cette idée centrale est abordée dans la section suivante.

5.4 PROCESSUS GAUSSIENS ET APPRENTISSAGE ACTIF

Dans cette section, les processus gaussiens (PG) sont introduits pour manipuler des espaces d'état et d'action continus et pallier la difficulté liée à des budgets d'observations restreints. Des algorithmes efficaces en données sont proposés à la fois pour le Q -learning et la programmation dynamique à l'aide du krigeage et de l'optimisation bayésienne, deux techniques basées sur les PG. Ils sont ensuite appliqués dans le cadre de l'apprentissage de la politique de planification des CPDV en reconnaissance active. Une série d'expérimentations est réalisée à la section 5.5 afin de comparer les performances de ces algorithmes aux implémentations de référence (décrites à la section 5.3).

5.4.1 Rappels sur les processus gaussiens

Les rappels effectués dans cette section sont basés sur les travaux de [Jones, 2001; Rasmussen et Williams, 2006].

Considérons un processus associant à chaque entrée $\mathbf{u} \in \mathbb{U}$ une sortie scalaire $y(\mathbf{u})$. Étant donné un jeu d'entrées initial de taille n , $\mathcal{U}_n = (\mathbf{u}^{(1)}, \dots, \mathbf{u}^{(n)})^T$ et les sorties correspondantes $\mathbf{y}_n = (y^{(1)}, \dots, y^{(n)})^T$, l'objectif est d'inférer la fonction y (inconnue) génératrice des sorties par une fonction de régression ou prédicteur Y , appelé aussi prédicteur par krigeage⁴. La distribution a posteriori de Y sur sa famille d'appartenance est

$$P(Y | \mathbf{y}_n, \mathcal{U}_n) \propto P(\mathbf{y}_n | Y, \mathcal{U}_n)P(Y) \quad (5.18)$$

$P(\mathbf{y}_n | Y, \mathcal{U}_n)$ représente la probabilité d'observer \mathbf{y}_n étant donné le jeu initial d'entrées et le prédicteur, et $P(Y)$ est la connaissance a priori sur le prédicteur, reflétant les hypothèses sur sa complexité. Cette probabilité a priori sur Y est un processus gaussien. Elle est notée :

$$Y \sim \mathcal{GP}(m(\cdot), k(\cdot, \cdot)). \quad (5.19)$$

$m(\cdot)$ est la fonction moyenne du processus et $k(\cdot, \cdot)$ est une fonction de covariance (ou noyau) définissant un produit scalaire dans un espace éventuellement non euclidien. En particulier, pour toute entrée \mathbf{u} , $Y(\mathbf{u})$ est exprimée par :

$$Y(\mathbf{u}) = \mathbf{f}^T(\mathbf{u}) \mathbf{b} + Z(\mathbf{u}) \quad (5.20)$$

où $\mathbf{f}(\mathbf{u})$ est un vecteur de régression (par exemple constant ou polynomial en \mathbf{u}) projetant tout vecteur \mathbf{u} dans un espace de dimension n_b supérieure, \mathbf{b} est un vecteur de coefficients de régression à estimer, et $Z(\cdot)$ est un processus gaussien de moyenne nulle et de fonction de covariance $k(\cdot, \cdot)$. De cette manière, l'incertitude sur $Y(\mathbf{u})$ est modélisée par $Z(\mathbf{u})$. Avec ces notations, nous avons $m(\mathbf{u}) = \mathbf{f}^T(\mathbf{u}) \mathbf{b}$. La prédiction par la fonction $m(\cdot)$ seule est supposée entachée d'erreur en chaque point. L'idée du prédicteur par krigeage repose sur l'hypothèse d'une corrélation de l'erreur entre chaque paire de points. Cette corrélation est représentée par la fonction $k(\cdot, \cdot)$. En première approche, plus les deux points sont proches, plus leur corrélation est grande [Schonlau, 1997]. La corrélation étant inconnue, elle est modélisée par :

$$k(Z(\mathbf{u}^{(i)}), Z(\mathbf{u}^{(j)})) = \sigma_Z^2 \text{Corr}(\mathbf{u}^{(i)}, \mathbf{u}^{(j)}) \quad (5.21)$$

4. Le terme krigeage (en anglais : *Kriging*) a été donné par le géophysicien français G. Matheron en hommage aux travaux pionniers de D. G. Krige pour l'exploitation des mines d'or en Afrique du Sud.

où σ_Z^2 est la variance du processus et $\text{Corr}(\cdot, \cdot)$ est une fonction de corrélation paramétrique. La fonction de corrélation adoptée ici, qui est adaptée à de nombreux contextes, est la fonction puissance exponentielle [Santner et al., 2003] :

$$\text{Corr}(\mathbf{u}^{(i)}, \mathbf{u}^{(j)}) = \exp\left(-\sum_{k=1}^{\dim(\mathbf{u})} \left|\frac{\mathbf{u}_k^{(i)} - \mathbf{u}_k^{(j)}}{\beta_k}\right|^{\rho_k}\right) \quad (5.22)$$

où les paramètres $\beta_k > 0$ sont des facteurs d'échelle qui déterminent la vitesse de décroissance de l'influence mutuelle des points avec leur distance. Les paramètres ρ_k reflètent la régularisation de la fonction de régression et doivent être fixés a priori. Le prédicteur par *krigeage empirique* est adopté, ce qui signifie que tous les autres paramètres sont estimés automatiquement à partir des mesures, par maximum de vraisemblance. Cela permet une plus grande flexibilité ainsi qu'une plus grande autonomie du prédicteur, contrairement à [Deisenroth et al., 2009] où tous les paramètres sont fixés à l'avance.

Pour estimer les paramètres \mathbf{b} , σ_Z^2 et β_k ($k = 1, \dots, \dim(\mathbf{u})$) par le critère du maximum de vraisemblance, définissons tout d'abord par \mathbf{C} la matrice $n \times n$ telle que

$$\mathbf{C}_{ij} = \text{Corr}(\mathbf{u}^{(i)}, \mathbf{u}^{(j)}) \quad (5.23)$$

et \mathbf{F} la matrice de taille $n \times n_b$ telle que

$$\mathbf{F} = \left(\mathbf{f}(\mathbf{u}^{(1)}), \dots, \mathbf{f}(\mathbf{u}^{(n)})\right)^T \quad (5.24)$$

Avec ces notations, la fonction de vraisemblance s'écrit :

$$\frac{1}{(2\pi)^{\frac{n}{2}} (\sigma_Z^2)^n \det(\mathbf{C})^{\frac{1}{2}}} \exp\left[-\frac{(\mathbf{y}_n - \mathbf{F}^T \mathbf{b})^T \mathbf{C}^{-1} (\mathbf{y}_n - \mathbf{F}^T \mathbf{b})}{2\sigma_Z^2}\right] \quad (5.25)$$

En pratique, il est préférable d'utiliser la fonction de log-vraisemblance, qui est définie par :

$$-\frac{n}{2} \log(\sigma_Z^2) - \frac{n}{2} \log(\det(\mathbf{C})) - \frac{(\mathbf{y}_n - \mathbf{F}^T \mathbf{b})^T \mathbf{C}^{-1} (\mathbf{y}_n - \mathbf{F}^T \mathbf{b})}{2\sigma_Z^2} \quad (5.26)$$

Les estimateurs $\hat{\mathbf{b}}$ et $\hat{\sigma}_Z^2$ sont obtenus en annulant les dérivées de la log vraisemblance (5.26) respectivement par rapport à \mathbf{b} et à σ_Z^2 . Nous obtenons :

$$\hat{\mathbf{b}} = \left(\mathbf{F}^T \mathbf{C}^{-1} \mathbf{F}\right)^{-1} \mathbf{F}^T \mathbf{C}^{-1} \mathbf{y}_n \quad (5.27)$$

$$\hat{\sigma}_Z^2 = \frac{(\mathbf{y}_n - \mathbf{F}^T \hat{\mathbf{b}})^T \mathbf{C}^{-1} (\mathbf{y}_n - \mathbf{F}^T \hat{\mathbf{b}})}{n} \quad (5.28)$$

Les estimateurs de β_k ($k = 1, \dots, \dim(\mathbf{u})$) sont obtenus de la même manière (se référer à [Sasena, 2002] pour les détails de l'estimation).

Étant donnée une nouvelle entrée $\mathbf{u} \in \mathbb{U}$, notons $\mathbf{c}(\mathbf{u})$ le vecteur de taille n tel que

$$\mathbf{c}(\mathbf{u}) = \left[\text{Corr}(\mathbf{u}, \mathbf{u}^{(1)}), \dots, \text{Corr}(\mathbf{u}, \mathbf{u}^{(n)})\right]^T. \quad (5.29)$$

L'ajout de $\mathbf{u} \in \mathbb{U}$ dans la log-vraisemblance (5.26) conduit à la log-vraisemblance augmentée. Elle est obtenue en remplaçant \mathbf{y}_n par $(\mathbf{y}_n^T, y(\mathbf{u}))^T$ et \mathbf{C} par $\begin{pmatrix} \mathbf{C} & \mathbf{c}(\mathbf{u}) \\ \mathbf{c}(\mathbf{u})^T & 1 \end{pmatrix}$. En particulier, le terme de la log-vraisemblance augmentée qui dépend de $y(\mathbf{u})$ est :

$$-\frac{\begin{pmatrix} \mathbf{y}_n - \mathbf{F}^T \hat{\mathbf{b}} \\ y(\mathbf{u}) - \mathbf{f}^T(\mathbf{u}) \hat{\mathbf{b}} \end{pmatrix}^T \begin{pmatrix} \mathbf{C} & \mathbf{c}(\mathbf{u}) \\ \mathbf{c}(\mathbf{u})^T & 1 \end{pmatrix}^{-1} \begin{pmatrix} \mathbf{y}_n - \mathbf{F}^T \hat{\mathbf{b}} \\ y(\mathbf{u}) - \mathbf{f}^T(\mathbf{u}) \hat{\mathbf{b}} \end{pmatrix}}{2\hat{\sigma}_Z^2}. \quad (5.30)$$

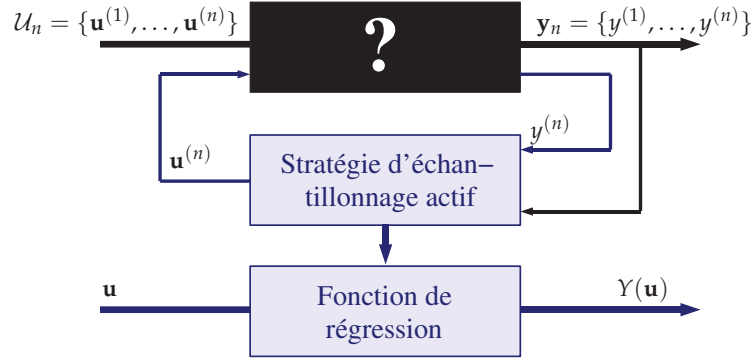


FIGURE 5.5 – Échantillonnage actif par processus gaussiens. Selon la stratégie d'échantillonnage choisie, la fonction de régression peut être utilisée à la fois comme un prédicteur non biaisé et pour l'optimisation globale.

En utilisant la formule d'inversion d'une matrice par blocs (cf. [Horn et Johnson, 1990]) et en annulant la dérivée de (5.30) par rapport à $y(\mathbf{u})$, le prédicteur de la moyenne du processus gaussien, appelé aussi prédicteur par krigeage, est donné par :

$$\hat{Y}(\mathbf{u}) = \mathbf{f}^T(\mathbf{u}) \hat{\mathbf{b}} + \mathbf{c}(\mathbf{u})^T \mathbf{C}^{-1} (\mathbf{y}_n - \mathbf{F}\hat{\mathbf{b}}) \quad (5.31)$$

Ce prédicteur, de complexité linéaire avec la taille de \mathbf{y}_n , vérifie $\hat{Y}(\mathbf{u}^{(i)}) = y^{(i)}$ pour le jeu initial d'entrées. Une autre propriété intéressante, cruciale au regard de la fiabilité de l'estimation et de l'optimisation globale, est la connaissance de la variance de la prédiction en \mathbf{u} , notée $\hat{\sigma}^2(\mathbf{u})$. Elle est obtenue en annulant la dérivée seconde par rapport à $y(\mathbf{u})$ de la log-vraisemblance augmentée. Il vient :

$$\hat{\sigma}^2(\mathbf{u}) = \hat{\sigma}_Z^2 \left(1 - \mathbf{c}(\mathbf{u})^T \mathbf{C}^{-1} \mathbf{c}(\mathbf{u}) \right) \quad (5.32)$$

Cette connaissance de la variance de la prédiction offre la possibilité d'élaborer des stratégies d'échantillonnage actif (là où cette variance est forte), permettant une prédiction adaptée selon des objectifs spécifiques. Deux objectifs particuliers considérés dans la suite, qui sont la prédiction sans biais et l'optimisation globale. Le principe d'échantillonnage actif est illustré par la figure 5.5. Notons que si le processus $y(\cdot)$ est supposé perturbé par un bruit gaussien additif $\mathcal{H}(0, \sigma_\epsilon^2)$, les équations (5.31) et (5.32) sont modifiées en substituant $\mathbf{C} + \sigma_\epsilon^2 \mathbf{I}$ à \mathbf{C} [Rasmussen et Williams, 2006].

5.4.2 Q-learning et processus gaussiens

Les processus gaussiens définis précédemment et l'échantillonnage actif qu'ils permettent sont ici couplés au Q-learning pour l'apprentissage de la politique de planification des CPDV.

Optimisation Bayésienne

Reprenons l'algorithme 3. La maximisation de la récompense future espérée (ligne 8) requiert une recherche de trajectoire \mathbf{a}_H basée sur la politique ϵ -greedy actuelle. Cependant, cette recherche n'est pas optimale car elle requiert qu'une partie des actions soit aléatoire pour éviter les optima locaux. Pour optimiser cette recherche (i.e. réduire le budget $budget_{OPT}$), la fonction $Q_{\omega^*}(\cdot)$ est ici modélisée par un processus gaussien $Q_{\omega^*}(\cdot) \sim \mathcal{PG}(m_Q(\cdot), k_Q(\cdot))$. Avec cette définition, l'algorithme 3 est modifié en introduisant la procédure d'optimisation EGO⁵ pour *optimisation globale efficace* [Jones et al., 1998]. EGO permet une stratégie d'échantillonnage actif plus efficace

5. Efficient Global Optimization.

pour la recherche du maximum global à chaque épisode. En particulier, pour une paire état-action (s_t, a_t) donnée, EGO permet de déterminer la sous-séquence de H actions $\mathbf{a}_H = (a_{t+1}, \dots, a_{t+H})^T \in \mathbb{A}(s_{t+1}) \times \dots \times \mathbb{A}(s_{t+H})$ maximisant la récompense cumulée espérée $R(\mathbf{a}_H)$ (5.14). EGO tire avantage du prédicteur par krigeage (5.31) et de la variance de prédiction (5.32) pour parvenir à une bonne approximation de l'optimum global à partir d'un budget d'échantillons restreint.

Le principe de EGO est le suivant : après un échantillonnage initial de n sous-séquences $\mathbf{a}_H^{(i)}$, $i = 1 \dots n$, et les récompenses correspondantes $R(\mathbf{a}_H^{(i)})$, le meilleur estimateur du maximum global disponible est

$$R^{max} = \max_{i=1 \dots n} R(\mathbf{a}_H^{(i)}). \quad (5.33)$$

Un nouvel échantillon $\mathbf{a}_H^{(n+1)}$, permettant d'améliorer l'estimateur précédent, est obtenu en maximisant l'amélioration espérée (EI)⁶ [Sasena, 2002; Jones et al., 1998] qui est définie par :

$$EI(\mathbf{a}_H, R^{max}) = \hat{\sigma}(\mathbf{a}_H) [u\Phi(u) + \phi(u)] \quad (5.34)$$

où

$$u = \frac{\hat{R}(\mathbf{a}_H) - R^{max}}{\hat{\sigma}(\mathbf{a}_H)}, \quad (5.35)$$

$\phi(\cdot)$ la densité de probabilité de la loi $\mathcal{N}(0, 1)$, $\Phi(\cdot)$ est la densité de probabilité cumulée de $\phi(\cdot)$, et $\hat{R}(\cdot)$ est le prédicteur par krigeage (5.31) de la récompense cumulée espérée (5.14). La procédure EGO est illustrée par la figure 5.6. Le calcul de l'EI est en pratique peu coûteux. La complexité provient uniquement de l'inversion de la matrice \mathbf{C} , cette inversion n'est cependant effectuée qu'une seule fois à chaque pas de temps. L'EI réalise ainsi un compromis entre une recherche locale dans l'espace des actions (par la maximisation de $\hat{R}(\mathbf{a}_H) - R^{max}$) et une exploration des zones inconnues (où $\hat{\sigma}(\mathbf{a}_H)$ est élevé). Ce critère est par conséquent très adapté pour l'optimisation globale. Un nouvel échantillon $\mathbf{a}_H^{(n+1)}$ est recherché itérativement jusqu'à épuisement du budget $budget_{OPT}$.

La combinaison de EGO avec l'algorithme 3 est résumée par l'algorithme 5, appelé GPQL-1⁷ pour *processus gaussiens avec Q-learning*. Alors que la stochasticité intrinsèque du processus est prise en compte dans le calcul de r (équation (5.2)), une stochasticité extrinsèque apparaît en considérant $Q_{\omega^*}(\cdot)$ comme un processus gaussien. Un calcul d'espérance supplémentaire est par conséquent réalisé (ligne 22). La valeur espérée de $Q_{\omega^*}(\cdot)$ correspond à sa moyenne m_Q .

Interpolation par krigeage

Dans cette section, le prédicteur par krigeage est mis à profit dans GPQL-1 pour améliorer encore l'efficacité en données de l'apprentissage. Après avoir optimisé la recherche de \mathbf{a}_H (i.e. en minimisant $budget_{OPT}$), l'idée est ici de sélectionner plus finement les actions a_t pendant l'apprentissage afin d'améliorer la fiabilité de la prédiction de $Q_{\omega^*}(\cdot)$ tout en conservant le même budget $budget_{INTERP}$.

L'interpolation par krigeage se déroule en deux étapes. La première est une étape d'initialisation, qui consiste en la sélection d'un jeu de n' actions $\mathbf{A}_{n'} = (a_t^{(1)}, \dots, a_t^{(n')})^T$ tel que $a_t^{(i)} \in \mathbb{A}(s_t)$ et du calcul de leur valeur correspondante $\mathbf{Q}_{n'} = (Q_{\omega^*}(a_t^{(1)}), \dots, Q_{\omega^*}(a_t^{(n')}))^T$. Le calcul du prédicteur par krigeage à l'aide de ce jeu initial permet d'obtenir un premier estimateur de $Q_{\omega^*}(\cdot)$, noté $\hat{Q}_{\omega^*}(\cdot)$. Dans la deuxième

6. Expected Improvement.

7. Gaussian Process with Q-Learning.

Algorithme 5: GPQL-1 : Q-learning avec EGO

Entrées : $budget_{INTERP}$, $budget_{OPT}$
 ω^* , γ , α , L , H , tol , $n < budget_{OPT}$
 $Q_{\omega^*}^{(0)}(\cdot)$ défini arbitrairement,

Sorties : politique de planification optimale $\Pi_{\omega^*}^*(\cdot)$

- 1 $\mathbf{X}_0 = \emptyset$; $\mathbf{V}_0 = \emptyset$;
- 2 $s_0 \leftarrow \{\omega^*, P(\omega \mid \mathbf{X}_0, \mathbf{V}_0) \text{ uniforme}, \mathbf{V}_0\}$;
- 3 extraire $\Pi_{\omega^*}^{(0)}(\cdot)$ de $Q_{\omega^*}^{(0)}(\cdot)$ (éq. (5.15));
- 4 **pour** chaque épisode $l = 0, \dots, L - 1$ **faire**
- 5 **répéter**
- 6 $t \leftarrow 0$; $s \leftarrow s_0$;
- 7 $a_t \leftarrow \epsilon$ -greedy $\Pi_{\omega^*}^{(l)}(s_t)$;
- 8 $R^{max} \leftarrow \text{EGO}(s_t, a_t, H, budget_{OPT})$;
- 9 **début EGO**
- 10 choisir $\mathbf{A}_n = (\mathbf{a}_H^{(1)}, \dots, \mathbf{a}_H^{(n)})$;
- 11 tel que $[a_{t+k}^{(i)} - tol, a_{t+k}^{(i)} + tol] \cap \mathbf{V}_{t+k} = \emptyset$, $k = 1, \dots, H$, $i = 1, \dots, n$;
- 12 calculer $\mathbf{R}_n = (R(\mathbf{a}_H^{(1)}), \dots, R(\mathbf{a}_H^{(n)}))$ à l'aide de (5.14);
- 13 **tant que** $n \leq budget_{OPT}$ **faire**
- 14 régresser un modèle par krigeage $\hat{R}(\cdot)$ sur $\{\mathbf{A}_n, \mathbf{R}_n\}$ (éq. (5.31));
- 15 calculer $R^{max} = \max_{i=1..n} R(\mathbf{a}_H^{(i)})$;
- 16 calculer $\mathbf{a}_H^{(n+1)} = \max_{\mathbf{a}_H} \text{EI}(\mathbf{a}_H, R^{max})$ à l'aide de $\hat{R}(\cdot)$;
- 17 tel que $[a_{t+k}^{(n+1)} - tol, a_{t+k}^{(n+1)} + tol] \cap \mathbf{V}_{t+k} = \emptyset$, $k = 1, \dots, H$;
- 18 calculer $R(\mathbf{a}_H^{(n+1)})$;
- 19 ajouter $R(\mathbf{a}_H^{(n+1)})$ à \mathbf{R}_n et ajouter $\mathbf{a}_H^{(n+1)}$ à \mathbf{A}_n ;
- 20 $n \leftarrow n + 1$;
- 21 **retourner** $R^{max} = \max_{i=1..n, budget_{OPT}} R(\mathbf{a}_H^{(i)})$;
- 22 $Q_{\omega^*}^{(l+1)}(a_t) \leftarrow \max \left\{ Q_{\omega^*}^{(l)}(a_t), \mathbb{E}_Q \left[Q_{\omega^*}^{(l)}(a_t) + \alpha \left[r(s_t, a_t) + \gamma R^{max} - Q_{\omega^*}^{(l)}(a_t) \right] \right] \right\}$;
- 23 **jusqu'à** $budget_{INTERP}$ épuisé;
- 24 obtenir $\hat{Q}_{\omega^*}^{(l+1)}(a_t)$ par interpolation (éq. 5.16);
- 25 extraire $\Pi_{\omega^*}^{(l+1)}(\cdot)$ à partir de $\hat{Q}_{\omega^*}^{(l+1)}(\cdot)$ (éq. (5.15));
- 26 $\Pi_{\omega^*}^*(\cdot) = \Pi_{\omega^*}^{(L)}(\cdot)$;




FIGURE 5.6 – Illustration de l’algorithme EGO ; à gauche : recherche de la récompense maximale dans l’espace continu des actions ; à droite : amélioration espérée (normalisée) à chaque pas et échantillonnage (i.e. sélection des actions) à sa valeur maximale.

étape, une recherche récursive de l’échantillon suivant est effectuée à l’endroit où la variance de la prédiction (5.32) est maximale, jusqu’à épuisement du budget $budget_{INTERP}$. De cette manière, l’interpolation effectuée minimise l’erreur de prédiction en tout point. Le prédicteur obtenu est également appelé BLUP⁸ pour *meilleur prédicteur linéaire sans biais*. L’algorithme 6 résume la nouvelle procédure de Q -learning couplée à EGO et à l’interpolation par krigeage. Cette procédure est baptisée GPQL-2. La différence entre GPQL-1 et GPQL-2 est résumée par la table 5.1.

5.4.3 Programmation dynamique et processus gaussiens

Dans cette section, le problème d’apprentissage sans modèle de la politique de planification des CPDV dans des espaces continus est résolu par programmation dynamique.

Mise en œuvre

L’état final du système, s_T , est défini ici par une connaissance parfaite de la classe (i.e. une probabilité a posteriori de 1 et une longueur de séquence nulle). Bien que cet état idéal soit en pratique non atteignable, il reflète les critères d’optimalité de la politique de planification définis à la section 2.4.3. La programmation dynamique consiste à déterminer de manière itérative les T actions qui permettent de passer de l’état final à l’état initial s_0 en un coût minimal. s_0 est l’état de connaissance correspondant à une distribution a posteriori uniforme sur Ω . Le coût d’une action à partir de l’état courant est défini par $-r_t$, où r_t est donné par l’équation (5.11).

Chaque itération requiert une optimisation de la fonction de valeur de l’état $V(s_t)$ sur des espaces d’état et d’action continus. La récente stratégie GPDP⁹ [Deisenroth et al., 2009], combinant processus gaussiens et programmation dynamique, consiste tout d’abord à régresser un modèle de prédiction par krigeage des fonctions V et Q à partir d’un échantillonnage sur une grille régulière, puis met en œuvre un algorithme d’optimisation classique. Cette stratégie permet une optimisation sur des espaces continus. Ici, nous proposons d’exploiter davantage les bénéfices des processus gaussiens en effectuant l’optimisation globale par EGO et l’échantillonnage actif sous-jacent. Comme pour le Q -learning, cela consiste en une meilleure utilisation du budget $budget_{OPT}$ (cf. section 5.4.2). Cette nouvelle procédure, appelée DPEGO¹⁰, est résumée par l’algorithme 7.

8. Best Linear Unbiased Predictor.

9. Gaussian Process Dynamic Programming.

10. Dynamic Programming with Efficient Global Optimization.

Algorithme 6: GPQL-2 : Q-learning avec EGO et interpolation par krigeage.

Entrées : $budget_{INTERP}, budget_{OPT}$
 $\omega^*, \gamma, \alpha, H, tol, n' < budget_{INTERP}$

Sorties : politique de planification optimale $\Pi_{\omega^*}^*(\cdot)$

- 1 $\mathbf{X}_0 = \emptyset; \mathbf{V}_0 = \emptyset;$
- 2 $s_0 \leftarrow \{\omega^*, P(\omega | \mathbf{X}_0, \mathbf{V}_0) \text{ uniforme}, \mathbf{V}_0\};$
- 3 $t \leftarrow 0; s \leftarrow s_0;$
- 4 choisir $\mathbf{A}_{n'} = \left(a_t^{(1)}, \dots, a_t^{(n')}\right)^T$ dans $\mathcal{A}(s_t);$
- 5 tel que $[a_t^{(i)} - tol, a_t^{(i)} + tol] \cap \mathbf{V}_t = \emptyset, i = 1, \dots, n';$
- 6 calculer $\mathbf{Q}_{n'} = \left(Q_{\omega^*}(a_t^{(1)}), \dots, Q_{\omega^*}(a_t^{(n')})\right)^T$ à l'aide de l'éq. (5.13) et EGO (lignes 10 à 21 de l'algo. 5);
- 7 **répéter**
- 8 $t \leftarrow 0; s \leftarrow s_0;$
- 9 régresser un modèle par krigeage $\widehat{Q}_{\omega^*}(\cdot)$ sur $\{\mathbf{A}_{n'}, \mathbf{Q}_{n'}\}$ (éq. (5.31));
- 10 déterminer $a_t^{(n'+1)} = \underset{a_t}{\operatorname{argmax}} \widehat{\sigma}^2(a_t)$ (éq. (5.32));
- 11 tel que $[a_t^{(n'+1)} - tol, a_t^{(n'+1)} + tol] \cap \mathbf{V}_t = \emptyset;$
- 12 calculer $Q_{\omega^*}(a_t^{(n'+1)})$ (idem que ligne 6);
- 13 ajouter $Q_{\omega^*}(a_t^{(n'+1)})$ à $\mathbf{Q}_{n'}$; ajouter $a_t^{(n'+1)}$ à $\mathbf{A}_{n'}$;
- 14 $n' \leftarrow n' + 1;$
- 15 **jusqu'à** $budget_{INTERP}$ épuisé;
- 16 extraire $\Pi_{\omega^*}^*(\cdot)$ à partir de $\widehat{Q}_{\omega^*}(\cdot)$ (éq. (5.15));

Le calcul de l'espérance relativement à $Q_{\omega^*}(\cdot)$, provenant de la stochasticité extrinsèque du processus gaussien, est réalisé de la même manière que pour le Q-learning, en prenant la valeur moyenne du processus gaussien. La politique de sélection des CPDV issue de DPEGO consiste en une séquence de T actions qui sont directement obtenues et ne nécessitent pas, comme en Q-learning, de maximisation des fonctions de valeur.

5.5 ÉVALUATIONS

Dans cette section, les algorithmes GPQL-1 (algorithme 5), GPQL-2 (algorithme 6) et DPEGO (algorithme 7) sont évalués pour l'apprentissage de la politique de planification des CPDV en reconnaissance active. Les méthodes classiques de résolution par itération de la politique en Q-learning (algorithme 3) et en programmation dynamique (algorithme 4) sont également mises en œuvre pour une comparaison.

Dispositif expérimental

Les conditions expérimentales sont décrites à la section 3.3. L'espace d'actions est ici mono-dimensionnel, i.e. $\mathcal{V} = \mathbb{R}$. La base de données utilisée pour la reconnaissance, identique à celle des chapitres précédents, est composée de huit classes. (cf. figure 4.4). Pour chaque classe, deux jeux d'observations ont été considérés. Un jeu d'apprentissage d'une part, pour l'apprentissage du classifieur et de la politique de planification et un jeu de test pour l'évaluation des performances. Comme précisé à la section 3.3, l'acquisition de ces jeux est réalisée à l'avance par commodité. Cependant, le budget d'observations d'apprentissage considéré dans ce chapitre étant très inférieur à la taille du jeu d'apprentissage, seul un sous-ensemble d'observations a été effectivement utilisé. La sélection de chaque obser-

	Technique d'échantillonnage pour l'optimisation globale	Technique d'échantillonnage pour l'interpolation	Paramètres d'entrée
QL (référence)	ϵ -greedy	ϵ -greedy	$budget_{INTERP}, budget_{OPT}, \omega^*, \gamma, \alpha, L, H, tol, Q_{\omega^*}^{(0)}(\cdot)$
GPQL-1	EGO	ϵ -greedy	$budget_{INTERP}, budget_{OPT}, \omega^*, \gamma, \alpha, L, H, tol, Q_{\omega^*}^{(0)}(\cdot), n$
GPQL-2	EGO	minimisation de (5.32)	$budget_{INTERP}, budget_{OPT}, \omega^*, \gamma, \alpha, H, tol, n, n'$
prog. dyn. (référence)	ϵ -greedy	-	$budget_{OPT}, \omega^*, V_{term}, \gamma, T, L, tol$
DPEGO	EGO	-	$budget_{OPT}, \omega^*, V_{term}, \gamma, T, tol, n$

TABLE 5.1 – Résumé des techniques d'apprentissage par renforcement considérées et paramètres associés.

vation d'apprentissage est interprétée comme un déplacement physique de l'agent. Elle est gouvernée par la politique d'échantillonnage impliquée dans la procédure d'apprentissage.

Description des images et choix du classifieur

La représentation des images est basée sur le descripteur GLOH [Mikolajczyk et Schmid, 2005]. Elle est décrite à la section 3.3.2. La dimension finale, réduite par ACP, est fixée à $d = 5$ (i.e. $\mathcal{X} = \mathbb{R}^5$). La modélisation des objets, l'apprentissage du classifieur (2.13) et le formalisme associé pour la reconnaissance multi-observations sont décrits à la section 3.2. Notons que le choix du classifieur est indépendant de l'apprentissage de la politique de planification. Seules ses propriétés statistiques sont nécessaires pour calculer la récompense (5.11).

Fonction de corrélation et paramètres

La fonction de corrélation adoptée dans les expérimentations est la fonction exponentielle puissance définie par (5.22). Rappelons que le krigeage empirique utilisé permet une estimation autonome par maximum de vraisemblance des paramètres d'échelle de cette fonction. Les paramètres de régularisation ont été fixé $\rho_k = 2$. Cette valeur, qui a été choisie empiriquement, offre en pratique une régularisation convenable pour le problème considéré et un choix plus affiné n'est pas critique.

5.5.1 Mise en œuvre du Q-learning

Pour chaque classe $\omega^* \in \Omega$, une politique de planification des CPDV a été apprise dans le but de discriminer cette classe parmi les autres de la base. Par conséquent, \mathcal{K} fonctions indépendantes $\hat{Q}_{\omega^*}^*(\cdot)$ ont été apprises avec $a_t = v_{t+1}$. Pendant la reconnaissance, la prochaine action est obtenue à partir de l'hypothèse actuelle ω_t , en utilisant la politique de planification $\Pi_{\omega^*}^*(\cdot)$ correspondante. Ce choix de découpler la sélection de la classe de l'espace des actions pendant l'apprentissage est motivé par deux raisons principales : premièrement, la planification par le critère max-adaptatif (qui est à la base de la récompense élémentaire utilisée (5.11)) repose sur la détermination préalable de l'hypothèse ω_t courante. Cette sélection en ligne de la politique de planification est similaire à la stratégie adoptée au chapitre 4. Par conséquent, l'indépendance entre les \mathcal{K} fonctions n'affecte pas le

Algorithme 7: DPEGO

Entrées : $budget_{OPT}$
 $\omega^*, V_{term}, \gamma, T, n < budget_{OPT}$

Sorties : politique de planification optimale $\Pi_{\omega^*}^*(\cdot)$ (séquence de T actions)

- 1 $\mathbf{X}_0 = \emptyset; \mathbf{V}_0 = \emptyset;$
- 2 $s_T \leftarrow \{\omega^*, P(\omega | \mathbf{X}_0, \mathbf{V}_0) = \mathbf{1}_{\{\omega=\omega^*\}}, \mathbf{V}_0\};$
- 3 $V^*(s_T) \leftarrow V_{term};$
- 4 **pour** $t = T - 1, \dots, 0$ **faire**
- 5 $\Pi_{\omega^*}^*(s_{t+1}) \leftarrow \text{EGO}(s_{t+1}, budget_{OPT});$
- 6 **début** EGO
- 7 choisir $\mathbf{A}_n = (a_t^{(1)}, \dots, a_t^{(n)})^T$ dans $\mathbb{A}(s_t);$
- 8 tel que $[a_t^{(i)} - tol, a_t^{(i)} + tol] \cap \mathbf{V}_t = \emptyset, i = 1, \dots, n;$
- 9 calculer, à l'aide de (5.13), $\mathbf{R}_n = (-r(s_t, a_t^{(1)}), \dots, -r(s_t, a_t^{(n)}))^T;$
- 10 **tant que** $n \leq budget_{OPT}$ **faire**
- 11 régresser un modèle par krigeage $\widehat{R}(\cdot)$ sur $\{\mathbf{A}_n, \mathbf{R}_n\}$ (éq. (5.31));
- 12 calculer $R^{min} = \min_{i=1..n} \{-r(a_t^{(i)})\};$
- 13 calculer $a_t^{(n+1)} = \max_{a_t} \text{EI}(a_t, R^{min})$ à l'aide de $\widehat{R}(\cdot);$
- 14 tel que $[a_t^{(n+1)} - tol, a_t^{(n+1)} + tol] \cap \mathbf{V}_t = \emptyset;$
- 15 calculer $-r(a_t^{(n+1)});$
- 16 ajouter $-r(a_t^{(n+1)})$ à \mathbf{R}_n et ajouter $a_t^{(n+1)}$ à $\mathbf{A}_n;$
- 17 $n \leftarrow n + 1;$
- 18 **retourner** $R^{min} = \min_{i=1..n} \{-r(a_t^{(i)})\}$
- 19 $\Pi_{\omega^*}^*(s_{t+1}) \leftarrow \mathbb{E}_Q [R^{min} + \gamma V^*(s_{t+1})];$
- 20 $V^*(s_t) \leftarrow Q_{\omega^*}(\Pi_{\omega^*}^*(s_{t+1}));$

résultat l'inférence. Deuxièmement, $Q_{\omega_t}^*(\cdot)$ est susceptible d'être discontinue lorsque la valeur de ω_t change. Ce découplage est également mis en œuvre par [Deisenroth et al., 2008] pour l'apprentissage de politiques discontinues que les processus gaussiens ne peuvent réaliser directement.

Itération de politique. L'implémentation de référence (section 5.3.1) a été réalisée en sélectionnant $budget_{INTERP} = 15$ actions par épisode à l'aide de la politique de recherche ϵ -greedy courante. Pour chaque action, la même politique a été utilisée dans la recherche du maximum global (ligne 8 de l'algorithme 3) pour différentes valeurs du budget de maximisation $budget_{OPT}$. L'itération de la politique s'est en pratique révélée plus performante pour une valeur de ϵ élevée. Par conséquent, une valeur initiale $\epsilon = 0,9$ a été choisie dans les expérimentations, puis a été diminuée progressivement au cours des épisodes avec un pas $\Delta_\epsilon = 0.05$ pour favoriser la convergence de la politique, comme préconisé par [Sutton et Barto, 1998]. À la fin de l'apprentissage, une interpolation par un noyau gaussien a été réalisée à l'aide de l'équation (5.16) avec différentes variances, qui définissent la bande passante du noyau. Comme le montre la figure 5.7, lorsque le nombre d'échantillons augmente, une bande passante élevée est requise pour obtenir une interpolation précise. Une variance égale à 0,005 a été choisie dans l'ensemble des expérimentations.




FIGURE 5.7 – Illustration de l'approximation de la fonction $Q(\cdot)$ par itération de la politique (ϵ -greedy) et interpolation par noyau gaussien ; a. : après 1 épisode ; b. : après 2 épisodes (avec $\text{budget}_{\text{INTERP}} = 15$ échantillons/épisode et $\text{budget}_{\text{OPT}} = 20$).




FIGURE 5.8 – Illustration de l'approximation de la fonction $Q(\cdot)$ avec EGO et interpolation par krigeage ; a. : après $\text{budget}_{\text{INTERP}} = 15$ échantillons ; b. : après $\text{budget}_{\text{INTERP}} = 30$ échantillons ($\text{budget}_{\text{OPT}} = 20$). L'échantillonnage actif est guidé par la réduction de la variance du prédicteur.

GPQL-1, 2. L'implémentation de EGO, utilisée dans les étapes d'optimisation globales de GPQL-1 et GPQL-2, a consisté en un jeu initial de trois échantillons par dimension dans l'espace de recherche, obtenus via un échantillonnage par hypercube latin (LHS¹¹), conduisant à $3 \times H \times v$ observations dans \mathbb{R}^v (où $\mathbb{R}^v = \mathcal{V}$), et poursuivant ensuite la politique d'échantillonnage actif propre à EGO avec différents budgets $\text{budget}_{\text{OPT}}$.

Dans GPQL-2, l'interpolation par krigeage a consisté en un jeu initial de $3 \times v$ observations obtenues par LHS dans \mathbb{R}^v . Une itération de la politique n'est plus requise dans ce cas, un seul épisode a donc été réalisé avec différents budgets $\text{budget}_{\text{INTERP}}$.

L'étape de mise à jour de $Q(\cdot)$ (équation (5.13)) a été réalisée en prenant pour paramètres $\alpha = 1$. Dans ce cas, chaque mise à jour consiste à remplacer la valeur de $Q_{\omega^*}(\cdot)$ par la nouvelle valeur de la récompense espérée. Dans l'ensemble des expérimentations, les paramètres $H = 2$ et $\gamma = 0,4$ ont été choisis. Une valeur supérieure de H pourrait être considérée sans contrainte supplémentaire, mais la valeur du facteur d'oubli choisie est telle que la récompense des actions au delà de cet horizon deviendrait négligeable.

Une fois la fonction continue $\hat{Q}_{\omega^*}^*(\cdot)$ estimée, la politique optimale $\Pi_{\omega^*}^*(\cdot)$ associée a été obtenue ici par une simple recherche des maxima locaux sur une grille d'échantillonnage fine. Cette recherche peut être effectuée hors ligne et ne nécessite aucun déplacement de l'agent.

Planification aléatoire et idéale Les algorithmes GPQL-1 et GPQL-2 sont comparés, en plus de l'implémentation de référence, à deux autres stratégies de planification : (i) une planification aléatoire, et une planification idéale. La planification aléatoire consiste en la sélection des CPDV selon une loi uniforme sur \mathcal{V} , et ne nécessite pas d'apprentissage. La planification idéale est celle obtenue pour des budgets d'observations d'apprentissage

11. Latin Hypercube Sampling.




FIGURE 5.9 – Erreur au sens des moindres carrés (RMSE) entre la fonction $Q(\cdot)$ réelle et les fonctions d'approximation obtenues avec les différentes stratégies considérées en fonction du budget d'interpolation (avec $\text{budget}_{OPT} = 20$). L'interpolation par noyau gaussien après itération de la politique et GPQL-1 donne de meilleurs résultats avec une variance faible du noyau. GPQL-2 et l'interpolation par krigeage surpassent toutes les autres méthodes.

illimités, i.e. par une recherche exhaustive dans l'espace des CPDV. En pratique, une discrétisation de l'espace a été considérée, de la même manière qu'au chapitre 4, c'est à dire à l'aide d'une grille régulière d'un pas de un degré sur l'azimut (soit 360 échantillons sur \mathcal{V}).

Résultats Les figures 5.7 et 5.8 illustrent un exemple de fonctions $Q_{\omega^*}(\cdot)$ apprises respectivement par une politique d'échantillonnage ϵ -greedy et par GPQL-2. Elles montrent une fiabilité de prédiction bien supérieure pour la deuxième méthode en comparaison avec la fonction $Q_{\omega^*}(\cdot)$ idéale. À la figure 5.9, l'évolution de l'erreur de prédiction au sens des moindres carrés en fonction du budget d'interpolation a été reportée pour les différentes stratégies considérées. EGO permettant une meilleure optimisation pour un budget budget_{OPT} donné, il en résulte une meilleure interpolation de GPQL-1 par rapport à l'itération de la politique. GPQL-2 et le prédicteur par krigeage améliorent encore la qualité de l'interpolation.

Au cours de la reconnaissance, les premières CPDV sont choisies au hasard. Puis, à chaque pas, l'agent planifie les prochaines CPDV selon la politique choisie associée à l'hypothèse courante ω_t . Cela permet en particulier de tenir compte de possibles changements de l'hypothèse courante. Chaque action effectuée est supposée être entâchée de bruit. Comme pour la phase d'apprentissage, une incertitude sur la pose a été considérée lors de la reconnaissance. Celle-ci est modélisée par une distribution gaussienne centrée sur les CPDV planifiées, avec un écart type de trois degrés. Cette incertitude est supposée provenir par exemple de l'imperfection des actionneurs. La reconnaissance est terminée dès que l'une des probabilités a posteriori franchit un seuil $P_{\max} = 0,95$ ou lorsque la longueur maximum de la séquence $T = 20$ est atteinte. Des valeurs plus faibles pourraient être considérées pour P_{\max} , mais le bénéfice d'une reconnaissance active serait moindre si la confiance requise n'était pas suffisamment élevée (cf. section 4.3). Les résultats reportés ont été obtenus par une moyenne des performances sur l'ensemble des classes, la performance de chaque classe étant elle-même obtenue par une moyenne sur 100 tests.

Les résultats sont reportés à la figure 5.10 en terme de performance cumulée de reconnaissance en fonction du nombre d'observations. Pour une longueur de séquence t donnée, chaque point donne le taux de performance de reconnaissance atteint en t observations ou moins. Les critères de performances utilisés pour les politiques de planification sont définis à la section 2.4.3. Dans la figure 5.11, les valeurs de $Aire_T$ pour les différentes politiques de planification sont comparées à $Aire_T^*$, la valeur obtenue avec la politique de planification idéale. Cette différence est notée Δ_{Aire_T} . Dans GPQL-1, l'amélioration de la maximisation due à EGO conduit à une valeur de $Aire_T$ supérieure à celle de la méthode par itération de

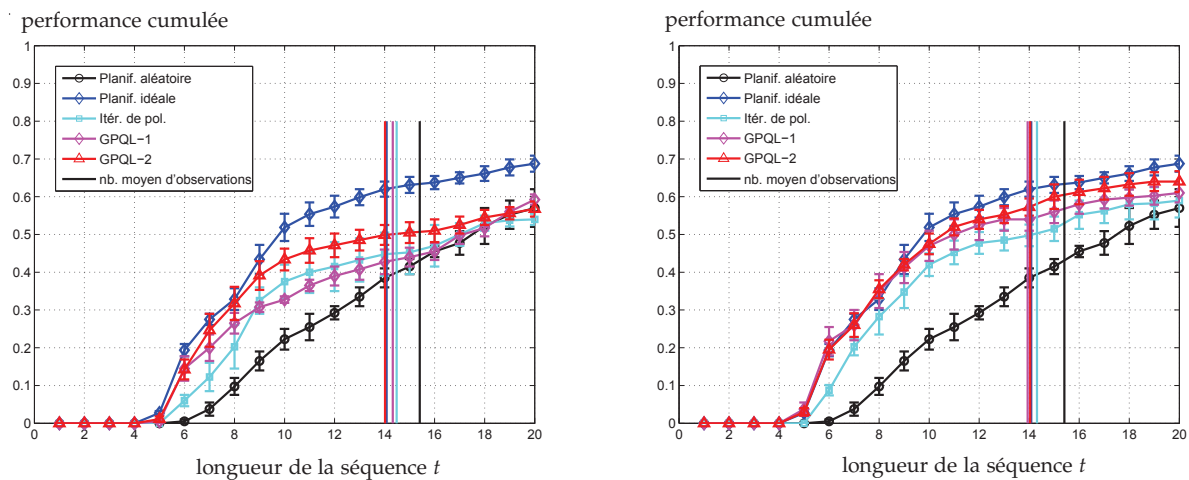


FIGURE 5.10 – Résultats pour le Q-learning - Performance de reconnaissance cumulée pour les différentes politiques de planification considérées. $\text{budget}_{OPT} = 20$; à gauche : après 1 épisode (itération de la politique et GPQL-1) ou $\text{budget}_{INTERP} = 15$ échantillons (GPQL-2); à droite : après 2 épisodes (itération de la politique et GPQL-1) ou $\text{budget}_{INTERP} = 30$ échantillons (GPQL-2).




FIGURE 5.11 – Résultats pour le Q-learning - différence du paramètre Aire_T entre la politique de planification idéale et les différentes approximations) en fonction du budget d'interpolation; à gauche : $\text{budget}_{OPT} = 10$; à droite : $\text{budget}_{OPT} = 20$.

la politique. GPQL-2 améliore davantage ce critère, en convergeant plus rapidement vers la performance maximale atteignable avec le même budget d'observations budget_{OPT} .

La figure 5.12 illustre un exemple de reconnaissance active à l'aide d'une planification apprise par GPQL-2 (le principe de la reconnaissance est le même pour les autres stratégies de planification). À chaque pas de temps, une première sélection de l'hypothèse ω_t est effectuée à partir de l'état courant du PDM. La fonction $\hat{Q}_{\omega^*}(\cdot)$ correspondante est ensuite maximisée sur l'espace des actions et les prochaines CPDV sont sélectionnées jusqu'à atteindre la confiance P_{\max} .

5.5.2 Mise en œuvre de la programmation dynamique

L'évaluation de DPEGO et sa comparaison avec l'implémentation de référence par itération de la politique (cf. section 5.3.2) ont été réalisées sur la même base de données que précédemment (figure 4.4).

Itération de la politique Dans l'implémentation de référence, chaque épisode a consisté en T itérations, ainsi que T procédures d'optimisation globale. L'optimisation est effectuée

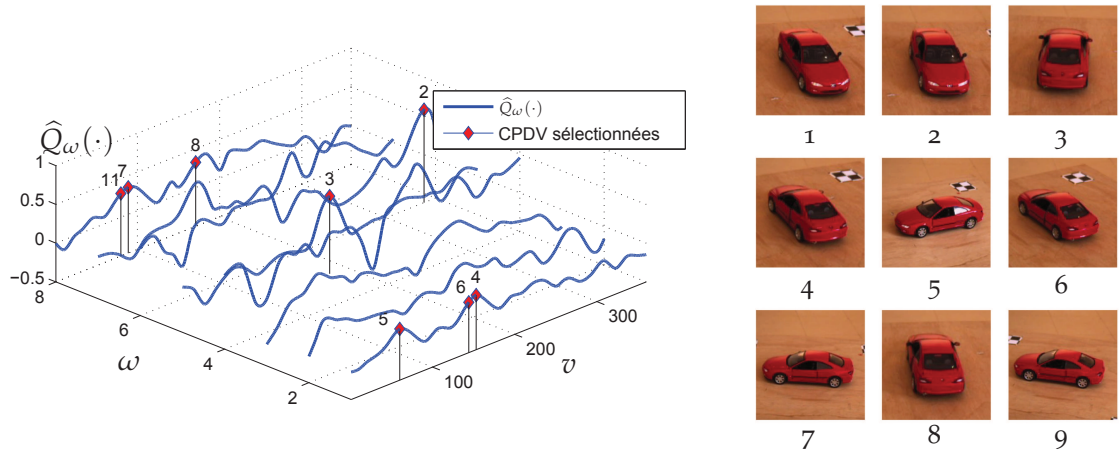


FIGURE 5.12 – Exemple de reconnaissance active avec GPQL-2; à gauche : fonctions $\hat{Q}_\omega(\cdot)$ obtenues par apprentissage. Au cours de la reconnaissance, l'agent émet différentes hypothèses sur la classe de l'objet et sélectionne les CPDV à l'aide de la politique correspondante; à droite : observations acquises pour la reconnaissance (la première observation est choisie au hasard).

en utilisant la politique de recherche ϵ -greedy courante avec cinq échantillons, conduisant à $budget_{OPT} = 5 \times L$ échantillons par itération après L épisodes.

DPEGO Dans DPEGO, la minimisation a été réalisée par EGO. Dans ce cas, un seul épisode a été effectué avec $budget_{OPT}$ échantillons par pas pour faciliter la comparaison avec l'implémentation de référence. Comme pour le Q-learning, des politiques de planification indépendantes ont été apprises pour chaque classe. Chaque politique donne la séquence d'actions optimale pour lever l'ambiguïté entre la classe considérée et le reste de la base.

Planification aléatoire et idéale Comme pour le Q-learning, une politique de planification aléatoire ainsi qu'une politique de planification idéale ont été considérées dans les comparaisons. La politique de planification idéale a été obtenue par une recherche exhaustive du minimum global à chaque pas de temps. En pratique, la recherche a été effectuée sur une grille régulière d'un pas de un degré sur l'espace des actions, conduisant à 360 échantillons sur l'azimut.

Résultats. La figure 5.13 reporte les courbes de performance cumulée de la reconnaissance, obtenues à l'aide des deux politiques de planification considérées pour des budget équivalents. DPEGO présente deux avantages sur l'approche classique : d'une part, la convergence des courbes de performance cumulée est plus rapide; d'autre part, Δ_{Aire_T} entre la politique idéale et DPEGO converge vers une valeur plus faible, comme le montre la figure 5.14.

5.6 DISCUSSIONS

Le couplage du krigeage (et les PG sous-jacents) avec le Q-learning et la programmation dynamique apportent tous deux une amélioration de l'efficacité en données pour l'apprentissage de la politique de planification, en comparaison avec les méthodes classiques sans modèle. Une première considération consiste à comparer cette efficacité entre GPQL-2 et DPEGO. Comme le montre la table 5.2, DPEGO nécessite moins d'interactions pour la tâche considérée. Cette supériorité peut être expliquée par la non nécessité de modéliser finement les fonctions de valeur dans DPEGO. L'interpolation n'est pas nécessaire car seule la connaissance de $Q_{\omega^*}(\cdot)$ et de $V(\cdot)$ à leur valeur minimale est utilisée pour l'apprentissage, ce qui réduit le nombre d'observations. Cependant, le Q-learning et GPQL-2

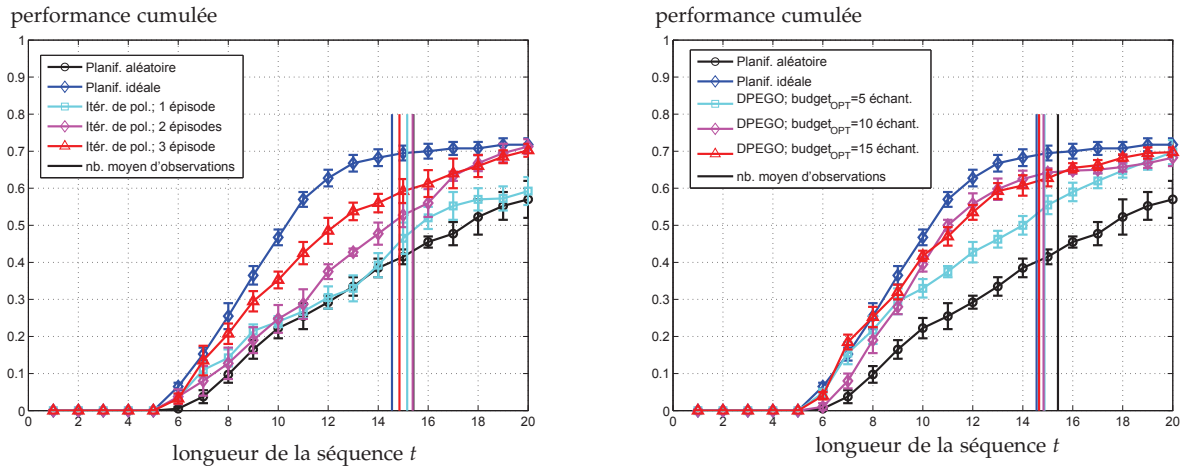


FIGURE 5.13 – Résultats pour la programmation dynamique - Performance de reconnaissance cumulée pour les différentes politiques de planification considérées et pour différentes valeurs de budget_{OPT} ; à gauche : itération de la politique et minimisation globale ϵ -greedy, avec 5 échantillons par pas ; à droite : DPEGO. Les courbes de la même couleur ont été obtenues avec des valeurs identiques de budget_{OPT} et peuvent être comparées directement entre les deux graphes.




FIGURE 5.14 – Résultats pour la programmation dynamique - différence du paramètre Aire_T entre la politique de planification idéale et les différentes stratégies d'apprentissage (cf. figure 5.13) pour un budget d'échantillons budget_{OPT} croissant.

permettent, par la connaissance de Q en tous points des espaces d'état et d'action, de dériver des politiques de planification plus complexes. En particulier, la séquence d'actions obtenue par la maximisation de $\widehat{Q}_{\omega^*}(\cdot)$ peut avoir une longueur plus importante (contrairement à DPEGO qui n'apprend que T actions) et être intégrée à un processus d'extraction de la politique finale plus sophistiqué (par exemple en faisant intervenir d'autres critères) et ce sans compromettre l'efficacité en données.

Un autre point important à relever concerne la comparaison des budgets d'apprentissage entre les méthodes développées dans ce chapitre et celles du chapitre 4. Dans l'espace des CPDV considéré dans les expérimentations, les budgets globaux (table 5.2) semblent suffisants pour construire les cartes de planification sur une grille dense (360 échantillons étaient nécessaires au chapitre 4). Mais une différence majeure dans ce chapitre, qui est issue de l'apprentissage par renforcement, est la prise en compte d'un horizon de planification non myope (défini par le paramètre $H > 0$). La récompense associée à une action fait intervenir les récompenses des actions futures. Il en résulte une estimation plus juste de l'utilité des CPDV, conduisant à une performance maximale de reconnaissance plus élevée. Si une planification non myope similaire avait été utilisée au chapitre 4, elle aurait nécessité 360^{H+1} observations dans le cas du Q -learning et $360 \times T$ observations dans le cas de




FIGURE 5.15 – Exemple de reconnaissance active avec DPEGO; gauche. Séquence des T CPDV optimales issues de l'apprentissage. L'axe z donne l'utilité de chaque CPDV (i.e. leur position dans la séquence). Au cours de la reconnaissance l'agent émet plusieurs hypothèses ω_t et sélectionne les CPDV à partir de la politique correspondante; droite. Observations acquises pour la reconnaissance (la première observation est choisi aléatoirement).

	politique de planification idéale ($Aire_T^*$)	Nombre total d'échantillons pour $\Delta_{Aire_T}=0,5$
GPQL-2	8,77	$budget_{INTERP} \times budget_{OPT} \times H = 1200$
DPEGO	8,81	$T \times budget_{OPT} = 500$

TABLE 5.2 – Comparaison du budget d'observations total requis par GPQL-2 et DPEGO pour atteindre des performances de reconnaissance similaires.

la programmation dynamique, ce qui correspond aux budgets des politiques de planifications "idéales" définies dans les expérimentations. De tels budgets sont beaucoup plus importants que ceux considérés par GPQL-2 et DPEGO. Notons toutefois que le nombre de déplacements effectifs de l'agent pourrait, pour toutes les stratégies, être revu à la baisse en réutilisant les observations déjà acquises, ce qui améliorerait l'efficacité en données (mais cela est sans effet sur l'efficacité calculatoire). Si une planification myope avait été considérée ici (i.e. $H = 0$), le budget global serait réduit à $budget_{INTERP}$ qui est de l'ordre de 30 observations. Cette valeur est nettement inférieure à celle du chapitre 4 et conforte l'intérêt du krigeage pour améliorer l'efficacité en données de l'apprentissage. L'amélioration apportée par une planification non myope est visible en comparant les courbes de performance cumulée (Figures 5.10 et 5.13) avec celles du chapitre 4 (figure 4.13, droite). Ces courbes sont rassemblées à la figure 5.16. Les politiques de planification obtenues par GPQL-2 et DPEGO sont supérieures à la fois en terme de $Aire_T$ et de $Perf_{max}$. Cette comparaison montre en revanche que le critère T_{moy} reste inchangé ($T_{moy} \approx 14$) par l'apport de l'apprentissage par renforcement.

Les valeurs de H et γ considérées ont été choisies dans le but de permettre une planification non myope ($H > 0$, $\gamma > 0$). Cependant, une optimisation de ces paramètres reste une piste à explorer car elle permettrait d'améliorer encore le bénéfice de cette approche. Elle consisterait à déterminer l'horizon de planification idéal et l'influence de chaque récompense durant l'apprentissage de manière à maximiser les performances de reconnaissance.




FIGURE 5.16 – Comparaison des performances pour la planification myope par critère max-adaptatif, GPQL-2, DPEGO et aléatoire.

CONCLUSION DU CHAPITRE

Ce chapitre a montré que les PG et la prédiction par krigeage qui en est issue, couplés à l'apprentissage par renforcement, pouvaient contribuer à déterminer la politique optimale de planification des CPDV pour une reconnaissance active. Mais au delà de cette application, les PG sont également susceptibles d'être bénéfiques pour de nombreux autres problèmes d'apprentissage par renforcement. Deux méthodes ont été analysées, le Q-learning et la programmation dynamique, conduisant à de nouveaux algorithmes (GPQL-1, 2 et DPEGO) pour l'apprentissage de la politique de planification des CPDV. Les processus gaussiens permettent un échantillonnage actif des observations d'apprentissage. Ils sont particulièrement bénéfiques lorsque les budgets d'observations sont limités (de l'ordre de 10 fois inférieurs à ceux du chapitre 4 dans le cas d'une planification myope). Ils conduisent à la fois à une interpolation précise (par le prédicteur par krigeage) et à une optimisation globale efficace (par EGO). Ils permettent également une mise en œuvre sans discrétisation des espaces de recherche (en particulier pour la résolution des équations de Bellman), évitant ainsi de possibles erreurs d'approximation. Les performances de reconnaissance active obtenues sur des bases de véhicules ont montré le bénéfice d'une planification non myope ainsi qu'une efficacité en données supérieure de GPQL-2 et de DPEGO par rapport à un apprentissage par renforcement classique.

Alors que le Q-learning a déjà été utilisé auparavant pour l'apprentissage de la planification des CPDV, le cadre de la programmation dynamique, avec DPEGO, a dans cette thèse pour la première fois été mis en œuvre en reconnaissance active et s'est révélé particulièrement bénéfique.

Ces stratégies de planification permettent, grâce à leur efficacité en données, un apprentissage réaliste de la planification des CPDV (i.e. en limitant le coût global d'acquisition). L'exploitation des observations d'apprentissage étant désormais améliorée, le souci de l'exploitation maximale des observations *au cours de la reconnaissance* est l'objet des chapitres suivants.

RÉSUMÉ

<i>Positionnement</i>	<ul style="list-style-type: none"> · Apprentissage de la politique de planification des CPDV pour la reconnaissance active. · Le budget d'observations d'apprentissage est limité. · Le classifieur est supposé connu et indépendant.
<i>Contributions</i>	<ul style="list-style-type: none"> · Un apprentissage actif par renforcement par l'utilisation du krigage permet une sélection des observations d'apprentissage les plus utiles. Deux approches sont considérées : GPQL et DPEGO. Elles offrent une efficacité en données supérieure aux méthodes classiques de Q-learning et de programmation dynamique. · Utilisation du critère max-adaptatif défini au chapitre 4 compatible avec une modélisation imparfaite des objets. · Horizon de planification non myope qui est bénéfique (les paramètres $Perf_{\max}$ et $Aire_T$ sont améliorés).
<i>Limitations</i>	<ul style="list-style-type: none"> · Les paramètres γ (facteur d'oubli des équations de Bellman) et H (horizon de planification) pourraient être optimisés.

PARTIE 3
TECHNIQUES DE CLASSIFICATION
SUPERVISÉE POUR LA RECONNAISSANCE
ACTIVE.

RECONNAISSANCE ACTIVE HIÉRARCHIQUE ET PLANIFICATION ADAPTATIVE MULTI-ÉCHELLES

6

Les chapitres de la partie précédente se sont attachés à la planification des CPDV pour la reconnaissance active, à travers d'une part la définition d'un critère de planification (chapitre 4) et d'autre part son apprentissage sous la contrainte d'un budget d'observations restreint (chapitre 5). Les fonctions de planification qui ont été conçues permettent une meilleure exploitation de la connaissance disponible sur la scène et conduisent à une performance supérieure pour une reconnaissance active "pleine échelle" (i.e. le classifieur attribue une classe unique à l'objet). Cependant, l'information totale peut tout de même s'avérer insuffisante lorsqu'un niveau élevé de confiance en l'interprétation est requis. Cet écueil est d'autant plus fréquent que le nombre de classes à discriminer est important, dû à l'augmentation de l'ambiguïté. Cela conduit soit à rejeter la prise de décision alors même que des observations ont été acquises, ce qui est synonyme d'efforts inutiles, soit à diminuer la confiance en l'inférence, ce qui est généralement effectué dans les travaux existants. Ce chapitre propose un cadre multi-échelles pour la reconnaissance active. Deux contributions majeures sont apportées pour limiter le rejet des décisions. Dans la première, un cadre de discernement dynamique est défini. Il permet d'exploiter systématiquement l'information collectée tout en maintenant le niveau de confiance requis en inférant la décision à une échelle d'interprétation intermédiaire. La deuxième contribution consiste en une nouvelle stratégie de planification adaptative multi-échelles (AME) compatible avec la classification hiérarchique définie. Elle permet d'exploiter l'émergence des conditions de prise de vue informatives au cours de la reconnaissance. Ces stratégies sont évaluées pour la reconnaissance active de véhicules sur trois bases de données de taille (et donc d'ambiguïté) croissante.

PLAN DU CHAPITRE

Ce chapitre est organisé de la manière suivante : la section 6.1 propose une revue des méthodes de classification hiérarchique pour la reconnaissance, ainsi que le besoin d'une interprétation multi-échelles en reconnaissance active. La reconnaissance active hiérarchique à l'aide d'un cadre de discernement dynamique est abordée à la section 6.2. La planification AME associée à la classification hiérarchique est présentée à la section 6.3. Les résultats de cette approche sur plusieurs bases de données de véhicules sont reportés en section 6.4 et discutés en section 6.5.

6.1 MOTIVATIONS ET TECHNIQUES D'INTERPRÉTATION MULTI-ÉCHELLES

6.1.1 Rappels de l'état de l'art

L'objectif de la reconnaissance automatique est de prédire la classe de l'objet à partir d'une mesure d'entrée avec une erreur minimale. La classe de l'objet, qui est définie par l'utilisateur, est dans la plupart des applications une information de haut niveau, parfois abstraite. Dans le cas de la reconnaissance d'objets à partir d'images, le résultat du classifieur est inféré à partir d'informations de bas niveau : les mesures extraites de la scène. Le passage de l'information brute à l'information abstraite avec une erreur de prédiction minimale a conduit au développement de nombreuses techniques d'apprentissage (cf. section 1.2 pour une revue des principaux algorithmes). Parmi elles, la classification multi-observations impliquée en reconnaissance active fait partie, comme pour la plupart des classifieurs, des techniques d'inférence dites "pleine échelle". La classification pleine échelle, appelée aussi "*full scale*" [Blanchard et Geman, 2005], classification directe [Burred et Lerch, 2003], classification globale [Xiao et al., 2007] ou "*flat classification*" [Silla et Freitas, 2011] ne considère que le niveau d'interprétation le plus fin (celui de la classe) sans considérer les interprétations intermédiaires. Cette stratégie, qui a été adoptée aux chapitres 4 et 5, est classiquement utilisée en classification multi-classes où une inférence pleine échelle immédiate est souvent recherchée [Lu et Weng, 2007]. Comme souligné par [Duda et al., 2001], une inférence pleine échelle repose sur l'hypothèse d'exclusion mutuelle entre les classes dans l'espace de représentation. Cependant, cette hypothèse est difficile à garantir en pratique, et des erreurs de classification apparaissent lorsque les classes se chevauchent dans cet espace. La reconnaissance active vise à préserver cette exclusion mutuelle en modifiant les CPDV via des stratégies de planification telles que celles développées aux chapitres 4 et 5. Cependant, la complexité de la scène et le budget limité d'observations pour la reconnaissance peut conduire à une incapacité à interpréter correctement à un tel niveau de précision à partir des données acquises. Ce manque d'information peut conduire à une augmentation du taux de rejet du classifieur.

Une première technique adoptée par [Vembu et Gärtner, 2010; Fürnkranz et al., 2008] consiste à mettre à profit le cadre probabiliste pour établir en sortie du classifieur un ordre de préférence des classes. Cependant, la confiance en l'interprétation par cette approche (la valeur des probabilités) ne garantit plus d'atteindre le seuil requis par l'utilisateur. Le maintien d'un niveau de confiance élevé est préférable. Pour cela, une organisation plus fine dans l'interprétation des observations, via une classification hiérarchique, est susceptible de permettre non seulement une interprétation provisoire plus efficace que l'ordonnement des classes, mais également une interprétation à pleine échelle plus performante [Dumais et Chen, 2000]. Cette approche, bien qu'utilisée dans d'autres travaux, n'a jusqu'à présent pas été proposée en reconnaissance active.

Une exploitation plus efficace de l'aspect séquentiel de la reconnaissance active est ici recherchée. Dans ce but, une structure hiérarchique d'interprétation est proposée. Ces structures sont inspirées des taxonomies dont l'objectif est de fournir une information provisoire interprétable par l'utilisateur via un ensemble de méta-classes définies à l'avance

et imbriquées entre elles (par exemple : ordre, famille, genre, espèce). La classification hiérarchique et les taxonomies sous-jacentes jouent un rôle important pour la classification multi-labels [Boutell et al., 2004; Brucker et al., 2010]. La classification hiérarchique mono-label, qui est l'approche adoptée ici, a également fait l'objet de nombreux travaux dès l'émergence des algorithmes de classification [Gordon, 1987] et demeure encore aujourd'hui un sujet actif [Silla et Freitas, 2011; Cesa-Bianchi et al., 2006]. L'imbrication des classes est représentée le plus souvent sous la forme d'un arbre ou d'un graphe. Ainsi, plus le nombre d'observations (ou tests) augmente, plus l'échelle d'interprétation attendue doit être fine. La définition des hiérarchies d'interprétation peuvent faire appel à une connaissance a priori, notamment dans les approches sémantiques [Marszalek et Schmid, 2007; Tusch et al., 2008]. Cette connaissance est cependant spécifique à la tâche à réaliser et souvent difficile à obtenir. Des méthodes d'extraction automatique de la hiérarchie ont été proposées à partir de mesures de similarité et agglomération dans l'espace de représentation des données [Chen et al., 2004; Vural et Dy, 2004; Madzarov et al., 2009]. Mais les hiérarchies obtenues, bien que valides, ne sont pas toujours optimales au sens de la tâche à réaliser [Gordon, 1987]. Elles supposent de plus que les données demeurent statiques dans l'espace de représentation, ce qui n'est pas compatible avec la reconnaissance active car les changements de CPDV induisent des fluctuations de représentation des objets dans cet espace. Ici, une organisation autonome est recherchée sans la connaissance de taxonomies pré-établies.

L'interprétation multi-échelles implique également une stratégie spécifique d'acquisition des données ou tests compatibles avec la structure de décision. L'ordre des tests joue une importance à la fois sur le coût de calcul global et sur la réussite de l'interprétation. Une approche par tests en cascade intégrés dans un classifieur par boosting est mise en œuvre par [Viola et Jones, 2001] pour la détection. L'ordre de chaque test dans la cascade conditionne la performance finale de l'algorithme. [Amit et al., 2004], ainsi que [Blanchard et Geman, 2005] adoptent une approche "coarse-to-fine" (CTF) pour la détection et la reconnaissance qui optimise la complexité globale de l'algorithme. Les tests sont caractérisés par leur puissance (taux de faux positifs), et leur étendue (capacité à être appliqués aux différentes situations rencontrées, ou taux de faux négatifs). Une stratégie de tests est déterminée par une optimisation conjointe de ces deux critères antagonistes. Les premiers tests sont étendus, peu coûteux et peu puissants alors que les derniers tests sont coûteux, puissants et très spécifiques. La hiérarchie d'interprétation obtenue découle de cette optimisation. Les hiérarchies obtenues contiennent la localisation spatiale et la caractéristique de l'image prise en compte dans chaque test. Cependant, ces approches CTF ne peuvent pas être utilisées directement ici car elles sont destinées à l'interprétation pleine échelle des données. Les résultats intermédiaires du classifieur ne sont pas interprétables directement par l'utilisateur. Les structures de tests sous-jacentes sont de plus définies hors ligne et restent statiques tout au long de la reconnaissance.

Une stratégie de tests adaptative, c'est-à-dire dépendante de l'état actuel du système (i.e. du nœud du graphe de hiérarchie) est susceptible d'être plus efficace en atteignant une résolution d'interprétation élevée en un minimum de tests. Un processus de décision séquentiel pour la reconnaissance multi-hypothèses a été proposé par [Herbin, 2003]. Les tests sont conditionnés à l'état actuel de connaissance et sont effectués de manière à réaliser un compromis entre l'échelle d'interprétation et la confiance en la décision. Ce compromis est inhérent aux systèmes de classification hiérarchiques [Tusch et al., 2008]. Il est particulièrement intéressant lorsque le nombre de classes en présence est important, point abordé ci-après.

6.1.2 Limites d'une reconnaissance active pleine échelle pour un nombre de classes élevé

L'augmentation du nombre de classes dans la base de données augmente simultanément l'ambiguïté entre les classes, rendant par conséquent l'interprétation pleine échelle

d'autant plus difficile, car la quantité d'information plus importante nécessaire à la classification n'est pas toujours disponible. La raréfaction des CPDV utiles pour la reconnaissance due à l'augmentation du nombre de classes est illustrée par la figure 6.1 à travers les cartes de planification par entropie, par critère adaptatif et max-adaptatif définis au chapitre 4. Plus le nombre de classes est élevé, plus l'ambiguïté augmente. Cela se traduit par une augmentation globale de l'entropie, ou bien une diminution globale des critères adaptatif et max-adaptatif. Les extrema locaux disparaissent sous l'augmentation de l'ambiguïté, et la planification devient inefficace.

Le premier aspect de l'approche proposée (section 6.3) consiste en une classification hiérarchique autonome pour la reconnaissance active où chaque niveau est directement interprétable par l'utilisateur. Les méta-classes sont formées par des sous-ensembles de la base de données, conduisant à un cadre de discernement dont la cardinalité diminue au cours de la reconnaissance. L'organisation des méta-classes est assurée de manière autonome par le classifieur lui-même.

Le deuxième aspect abordé dans ce chapitre (section 6.4) consiste à définir une stratégie de planification adaptative multi-échelles (AME) capable d'exploiter au maximum la hiérarchie d'interprétation définie. L'adaptation de la planification a ici un triple sens : en utilisant les critères adaptatif ou max-adaptatif définis au chapitre 4, elle permet (i) une sélection des CPDV en ligne (i.e. adaptée à l'état actuel de la reconnaissance) et (ii) adaptée à une modélisation imparfaite des objets. Elle permet également (iii) une sélection des CPDV conditionnée à la résolution actuelle de l'interprétation (i.e. la profondeur du graphe d'interprétation). L'acquisition d'une nouvelle observation est considérée comme un test adapté à l'échelle actuelle et permettant de progresser dans ce graphe. En particulier, l'émergence de CPDV informatives due à la réduction du cadre de discernement est capturée par la planification AME. L'apprentissage de la fonction de planification est indépendante du reste de la procédure. Dans ce chapitre, nous utiliserons la planification dérivée du chapitre 4. D'autres méthodes (comme celle définie au chapitre 5) peuvent également être utilisées.

6.2 RECONNAISSANCE ACTIVE HIÉRARCHIQUE

Cette section présente l'approche hiérarchique pour la reconnaissance active. Après une définition de la hiérarchie de classification (section 6.2.1), l'adaptation du classifieur à cette hiérarchie est définie (section 6.2.2).

6.2.1 Extraction de la hiérarchie de classification

La solution proposée face à l'augmentation de l'ambiguïté entre les classes consiste à définir le résultat de la classification sur une taxonomie permettant une interprétation intermédiaire. Ainsi, si le niveau de confiance atteint n'est pas suffisant pour prédire une unique classe, il peut néanmoins s'avérer suffisant pour atteindre un niveau de précision inférieur dans le graphe de hiérarchie, ce qui est, pour l'utilisateur, souvent préférable au rejet.

Avant d'aborder la classification hiérarchique, il est nécessaire de définir la notion de taxonomie de classes utilisée dans ce chapitre. Nous reprenons ici la définition de [Wu et al., 2004].

Taxonomie de classes

Définition 6.1 Une taxonomie (ou taxinomie¹) de classes est une hiérarchie de méta-classes, ou concepts de classes, structurées en arbre ou en graphe acyclique orienté (GAO) et définies sur un ensemble partiellement

1. Les deux orthographes sont possibles (cf. <http://www.universalis.fr/dictionnaire>).




FIGURE 6.1 – Évolution des critères de planification en fonction du nombre de classes de la base de données ; a. : entropie ; b. : critère adaptatif ; c. : critère max-adaptatif ; à gauche : 4 classes ; au centre : 8 classes ; à droite : 12 classes. Les cartes ont été obtenues par une moyenne sur l'ensemble des classes de la base.

ordonné (C, \prec) . C représente l'ensemble des méta-classes considérées pour la tâche à réaliser. L'opérateur \prec est une relation de type "est-un" qui est transitif et anti-réflexif. Les propriétés vérifiées par une taxonomie sont les suivantes :

- Le plus grand élément de C est unique. C'est la racine de l'arbre.
- $\forall c_i, c_j \in C$, si $c_i \prec c_j$, alors $c_j \not\prec c_i$.
- $\forall c_i \in C$, $c_i \not\prec c_i$.
- $\forall c_i, c_j, c_k \in C$, $c_i \prec c_j$ and $c_j \prec c_k \Rightarrow c_i \prec c_k$.

Notons que les méta-classes utilisées dans la définition précédente doivent être imbriquées afin de garantir les propriétés d'héritage. Ces méta-classes peuvent être des notions abstraites basées sur des ontologies (par exemple la méta-classe "espèce" est une méta-classe "genre"). Dans le cas considéré dans ce chapitre, l'approche consiste à rassembler hiérarchiquement les classes ambiguës. Les méta-classes sont alors formées par des sous-ensembles de classes, depuis la racine (l'ensemble des classes) jusqu'aux feuilles (chaque classe individuelle). La hiérarchie obtenue est structurée en graphe acyclique orienté (GAO) dans lequel chaque nœud peut avoir plusieurs parents. Cela permet d'obtenir une hiérarchie contenant les $2^{\mathcal{K}}$ méta-classes possibles, \mathcal{K} étant le nombre de classes, autorisant une organisation multi-échelles autonome par le classifieur. La figure 6.2 illustre le GAO obtenu pour une base de données de quatre classes.




FIGURE 6.2 – Graphe acyclique orienté pour la classification multi-échelles. Les nœuds et feuilles identiques ne sont pas rassemblés dans le graphe dans un souci de clarté. Les ovales bleus représentent les niveaux de décision possibles par la classification multi-échelles. Le rectangle arrondi rouge représente le niveau de décision dans le cas d'un classifieur pleine échelle.

6.2.2 Cadre de discernement dynamique

Rappels sur la classification multi-observations. Les notations et le formalisme utilisés pour une reconnaissance multi-observations ont été définis aux sections 2.2 et 2.3. Ils sont rappelés ici brièvement.

Soit $\Omega = \{1, \dots, \mathcal{K}\}$ l'ensemble des classes considérées pour la reconnaissance. Étant donnée une séquence de t observations $\mathbf{X}_t = \{x_1, \dots, x_t\}$ telle que $x_i \in \mathcal{X}$, associées à leur CPDV respectives $\mathbf{V}_t = \{v_1, \dots, v_t\}$ telles que $v_i \in \mathcal{V}$, le système doit inférer la classe de l'objet observé parmi l'ensemble Ω . Cette inférence est donnée par le maximum a posteriori

$$\omega^* = \underset{\omega \in \Omega}{\operatorname{argmax}} P(\omega \mid \mathbf{X}_t, \mathbf{V}_t) \quad (6.1)$$

La séquence d'observations $\mathbf{X}_t, \mathbf{V}_t$ représente l'état actuel de connaissance. À chaque nouvelle observation, les probabilités a posteriori sont actualisées par le schéma d'intégration (2.10).

Évolution en ligne du nombre d'hypothèses. Le cadre de discernement est défini par l'ensemble des hypothèses de classe susceptibles d'être attribuées à l'objet observé. Chaque nœud (ou méta-classe) du GAO de hiérarchie correspond à un cadre de discernement unique, et la hiérarchie permet d'envisager toutes les possibilités de méta-classes.

Pour chaque objet à classifier, le système parcourt le GAO depuis la racine. À chaque nœud rencontré, la méta-classe prédite par le classifieur conditionne le cadre de discernement pour toute la suite de la reconnaissance. Cette stratégie de focalisation d'attention, utilisée par [Amit et al., 2004] pour réduire l'étendue spatiale de la recherche en détection, est ici appliquée pour réduire progressivement le nombre d'hypothèses. Un cadre de discernement réduit permet d'envisager des tests plus spécialisés et ainsi favoriser le parcours en profondeur du graphe. Cependant, la réussite de chaque test est basée sur la réussite des tests précédents. Les classes non retenues à une échelle donnée sont définitivement exclues de l'ensemble des échelles inférieures. L'approche hiérarchique doit donc se prémunir de l'exclusion de la vraie classe de l'objet tout au long de la classification.

La racine de l'arbre est définie par $\Omega = \{1, \dots, \mathcal{K}\}$. La première question face à l'échec

précédent consiste à se demander sous quelle condition une classe peut être exclue du cadre de discernement avec certitude. Cela conduit à la définition des méta-classes.

Méta-classes d'objets. Soit $P_{\min} \in [0, \frac{1}{\mathcal{K}}[$, et ρ et q deux entiers naturels tels que $\rho + q = \mathcal{K}$. À l'instant t (i.e. après t observations), une méta-classe de cardinalité ρ est définie par

$$\Omega_t^{(\rho)}(P_{\min}) = \{\omega \in \Omega \mid P(\omega \mid \mathbf{X}_t, \mathbf{V}_t) > P_{\min}\}, \text{ tel que } \text{card}(\Omega_t^{(\rho)}(P_{\min})) = \rho \quad (6.2)$$

Ainsi, l'appartenance de l'objet à chaque méta-classe du GAO - et donc le parcours suivi dans la hiérarchie - est directement interprétable par l'utilisateur. En particulier, deux informations peuvent être obtenues : (i) la confiance accordée à chaque classe constituant la méta-classe, et (ii) la confiance globale accordée à la méta-classe. La première information est obtenue via les probabilités a posteriori $P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t)$, $k \in \Omega_t^{(\rho)}(P_{\min})$. La confiance en la méta-classe est exprimée par la probabilité d'appartenance de l'objet observé à $\Omega_t^{(\rho)}(P_{\min})$. Elle est définie par :

$$P(\omega \in \Omega_t^{(\rho)}(P_{\min}) \mid \mathbf{X}_t, \mathbf{V}_t) = \sum_{k \in \Omega_t^{(\rho)}(P_{\min})} P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t) \quad (6.3)$$

Notons $\bar{\Omega}_t^{(\rho)}(P_{\min})$ le complémentaire à Ω de $\Omega_t^{(\rho)}(P_{\min})$ tel que $\text{card}(\bar{\Omega}_t^{(\rho)}(P_{\min})) = q$. Chaque classe appartenant à $\bar{\Omega}_t^{(\rho)}(P_{\min})$ a été exclue avec un risque maximal P_{\min} . L'inégalité $\sum_{k \in \bar{\Omega}_t^{(\rho)}(P_{\min})} P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t) \leq qP_{\min}$ est donc vérifiée. Il vient :

$$P(\omega \in \Omega_t^{(\rho)}(P_{\min}) \mid \mathbf{X}_t, \mathbf{V}_t) \geq 1 - qP_{\min} \quad (6.4)$$

Cette équation fait apparaître deux comportements :

Premièrement, pour P_{\min} fixé, lorsque q augmente (i.e. l'échelle d'interprétation est de plus en plus fine), la confiance en la décision tend à diminuer. Cela reflète le compromis entre précision et confiance, et justifie l'intérêt d'une approche hiérarchique lorsque l'information nécessaire pour atteindre le niveau de précision maximal est insuffisante.

Deuxièmement, pour q fixé, lorsque P_{\min} augmente, la confiance en $\Omega_t^{(\rho)}(P_{\min})$ diminue également. Ce phénomène est expliqué par le risque plus important d'éliminer la vraie classe de l'objet dans les couches supérieures de la hiérarchie lorsque P_{\min} est élevé. Cependant, une valeur trop faible peut conduire à une évolution trop lente dans la hiérarchie, c'est-à-dire à une sous-exploitation de l'information acquise. Le seuil P_{\min} traduit par conséquent un compromis entre la fiabilité et la vitesse de l'interprétation (i.e. la vitesse de diminution du nombre d'hypothèses avec t). L'étude de ce compromis est réalisée à la section 6.5. La planification des CPDV pour une reconnaissance multi-échelles est maintenant abordée.

6.3 PLANIFICATION ADAPTATIVE MULTI-ÉCHELLES

La section précédente a montré que la reconnaissance active multi-échelles permettait une interprétation dès la première observation à l'aide d'un cadre de discernement évoluent dynamiquement et de manière autonome avec le classifieur. Dans cette section, une hiérarchie de planification complémentaire à la hiérarchie de classification est présentée (section 6.4.1), ainsi que les critères de planification associés (section 6.4.2).

6.3.1 Hiérarchie de planification

La hiérarchie d'interprétation définie pour la reconnaissance active (illustrée par la figure 6.2) permet jusqu'à présent d'exploiter l'information séquentielle collectée dès le

début du processus et de la rendre interprétable. Cependant, l'aspect "actif" de la reconnaissance est obtenu par une politique de planification qui jusqu'à présent fait intervenir l'ensemble des classes (la racine du GAO) pour la sélection des prochaines CPDV. Si le nombre de classes est trop élevé, les CPDV seront susceptibles d'être toutes aussi ambiguës les unes que les autres, conduisant à une inefficacité de la planification tout au long de la reconnaissance.

Une stratégie de planification adaptative multi-échelles est ici définie. Elle permet d'exploiter au mieux l'interprétation actuelle de l'objet observé. En plus de l'aspect adaptatif défini au chapitre 4 (i.e. l'adaptativité aux imperfections de la modélisation et l'adaptativité à l'état de connaissance actuel), une adaptativité à l'échelle d'interprétation est ajoutée. Elle permet de planifier les CPDV conditionnellement au cadre de discernement actuel. Ainsi, au fur et à mesure de la reconnaissance, la diminution du cadre de discernement et du nombre de classes en présence est susceptible de mettre en évidence des CPDV informatives qui étaient auparavant ambiguës à cause des classes supplémentaires. Le cadre de discernement étant dynamique, cette émergence d'information doit également être capturée dynamiquement par la stratégie de planification. Une hiérarchie de planification est pour cela construite conjointement à l'aide d'un GAO. Elle est illustrée par la figure 6.3 dans le cas d'une base de donnée de quatre classes.

6.3.2 Critères de planification multi-échelles

La définition des critères de planification multi-échelles pour une reconnaissance active hiérarchique est basée sur les critères adaptatif (4.5) ou max-adaptatif (4.6) définis au chapitre 4. Auparavant, il est nécessaire de redéfinir l'entropie intervenant dans ces critères. L'entropie, définie par l'équation (4.2), est l'information moyenne de la distribution a posteriori $P(\omega | x, v)$ telle que $\omega \in \Omega$. Pour une échelle d'interprétation inférieure donnée en dehors de la racine du GAO (voir la figure 6.2), les classes exclues du cadre de discernement n'apportent plus d'ambiguïté au classifieur. En notant $\Omega^{(\rho)}(P_{\min})$ le cadre de discernement constitué de ρ classes (la notion de temps est ici omise par simplification), l'entropie multi-échelles est définie par l'information moyenne relativement à $\Omega^{(\rho)}(P_{\min})$

$$\mathcal{E}_{\Omega^{(\rho)}(P_{\min})}(\omega | x, v) = - \sum_{\omega \in \Omega^{(\rho)}(P_{\min})} \zeta P(\omega | x, v) \log(\zeta P(\omega | x, v)) \quad (6.5)$$

où ζ est un coefficient de renormalisation défini par $\zeta = 1 / \sum_{\omega \in \Omega^{(\rho)}(P_{\min})} P(\omega | x, v)$. L'entropie espérée est obtenue par :

$$\mathcal{E}_{\Omega^{(\rho)}(P_{\min})}(\omega | v) = \mathbb{E}_{x, v_r | v} \mathcal{E}_{\Omega^{(\rho)}(P_{\min})}(\omega | x, v) \quad (6.6)$$

Le calcul des espérances des entropies espérées moyenne et conditionnelle sur $\Omega^{(\rho)}(P_{\min})$ est effectué respectivement à l'aide des équations (4.3) et (4.4).

À l'aide de la définition précédente de l'entropie (6.5), les critères adaptatifs (4.5) et

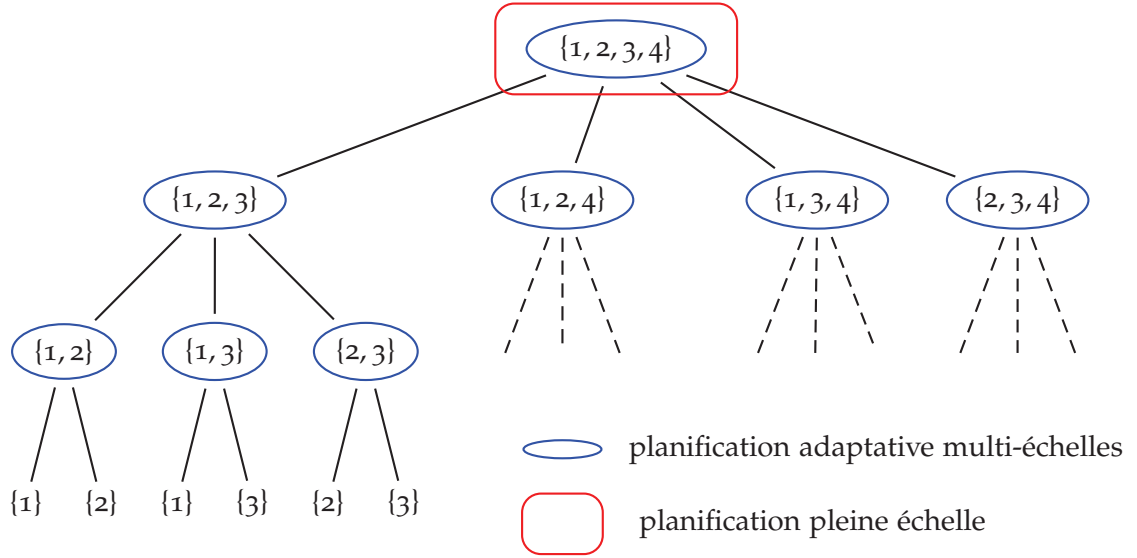


FIGURE 6.3 – Graphe acyclique orienté pour une planification multi-échelles des CPDV. Les nœuds et feuilles identiques ne sont pas rassemblés dans le graphe pour des raisons de clarté. Les ovales bleus représentent les niveaux de planification possibles par l'approche adaptative multi-échelles. Le rectangle arrondi rouge représente le niveau de planification dans le cas d'une reconnaissance active pleine échelle.

max-adaptatifs (4.6) sont exprimés dans le cadre multi-échelles de la manière suivante :

Critère adaptatif multi-échelles :

$$\mathcal{C}_{\Omega_t^{(\rho)}(P_{\min})}(\omega \mid v_{t+1}, k) = -(1 - \alpha) \frac{\mathcal{E}_{\Omega_t^{(\rho)}(P_{\min})}(\omega \mid v_{t+1})}{\mathcal{E}_0} + \alpha \zeta \mathbb{E}_{x_{t+1}, v_r \mid v_{t+1}} [P(\omega = k \mid x_{t+1}, v_{t+1})],$$

$$k \in \Omega_t^{(\rho)}(P_{\min}) \quad (6.7)$$

Critère max-adaptatif multi-échelles :

$$\mathcal{C}_{\Omega_t^{(\rho)}(P_{\min})}(\omega \mid v_{t+1}, k) = -(1 - \alpha) \frac{\mathcal{E}_{\Omega_t^{(\rho)}(P_{\min})}(\omega \mid v_{t+1})}{\mathcal{E}_0}$$

$$+ \alpha \zeta \mathbb{E}_{x_{t+1} \mid v_{t+1}, k} [P(\omega = k \mid x_{t+1}, v_{t+1})$$

$$- \max_{\substack{j \in \Omega_t^{(\rho)}(P_{\min}) \\ i \neq k}} P(\omega = i \mid x_{t+1}, v_{t+1})],$$

$$k \in \Omega_t^{(\rho)}(P_{\min}) \quad (6.8)$$

Les espérances sont obtenues de la même manière que pour l'entropie (équation (4.4)) Ainsi, en chaque nœud du GAO de classification, la sélection des prochaines CPDV est réalisée en trois étapes :

- 1- sélection du nœud homologue dans le GAO de planification,
- 2- sélection, parmi cet ensemble, du critère adaptatif correspondant à l'hypothèse actuelle,
- 3- planification des CPDV par la maximisation du critère sélectionné.

La procédure de reconnaissance active hiérarchique à l'aide de la planification adaptative multi-échelles est résumée par l'algorithme 8. Contrairement à la reconnaissance active pleine échelle (cf. chapitre 4, algorithme 2), lorsque le niveau de confiance P_{\max} n'est pas atteint après T observations, le rejet est avantageusement remplacé par une interprétation intermédiaire $\Omega_T^{(\rho)}(P_{\min})$ avec $1 \leq \rho < \mathcal{K}$.

Algorithme 8: Reconnaissance active hiérarchique par critère de planification adaptatif multi-échelles.

Entrées : Modèles : $P(x \mid \omega = k, v)$, $k = 1, \dots, \mathcal{K}$
 GAO de classification
 GAO de planification
 α , tol , P_{\max} , P_{\min} , T
 Conditions initiales : x_1, v_1

Sorties : Cadre de discernement $\Omega_t^{(\rho)}(P_{\min})$, $1 \leq \rho \leq \mathcal{K}$, $1 \leq t \leq T$

```

1  $\rho \leftarrow \mathcal{K}$ ;
2  $t \leftarrow 0$ ;
3  $\mathbf{X}_t = \emptyset$ ;
4  $\mathbf{V}_t = \emptyset$ ;
5 répéter
6    $P(v \mid \mathbf{X}_t, \mathbf{V}_t, \omega) = \mathbf{1}_{\{v=v_{t+1}\}}$ ;
7    $\mathbf{X}_{t+1} \leftarrow \mathbf{X}_t \cup x_{t+1}$ ;
8    $\mathbf{V}_{t+1} \leftarrow \mathbf{V}_t \cup v_{t+1}$ ;
9   Calculer  $P(\omega \mid \mathbf{X}_{t+1}, \mathbf{V}_{t+1})$ ,  $\omega \in \Omega_\rho$  (éq. (2.11));
10  pour chaque  $\omega \in \Omega_t^{(\rho)}(P_{\min})$  faire
11    si  $P(\omega \mid \mathbf{X}_{t+1}, \mathbf{V}_{t+1}) \leq P_{\min}$  alors
12       $\Omega_t^{(\rho)}(P_{\min}) \leftarrow \Omega_t^{(\rho)}(P_{\min}) \setminus \omega$ ;
13       $\rho \leftarrow \rho - 1$ ;
14   $k^* \leftarrow \underset{k}{\operatorname{argmax}} P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t)$ ;
15   $t \leftarrow t + 1$ ;
16   $\mathcal{C}^* \leftarrow \mathcal{C}_{\Omega_t^{(\rho)}(P_{\min})}(\omega \mid v_{t+1}, \omega = k^*)$  (éq. (6.7) ou (6.8));
17   $v_{t+1}^* = \underset{v_{t+1}}{\operatorname{argmax}} \mathcal{C}^*$ , tel que  $[v_{t+1} - tol; v_{t+1} + tol] \cap \mathbf{V}_t = \emptyset$ ;
18  Aller à  $v_{t+1}^*$ ; observer  $x_{t+1}$ ;
19 jusqu'à  $\max_k P(\omega = k \mid \mathbf{X}_t, \mathbf{V}_t) \geq P_{\max}$  ou  $t = T$ ;
20 si  $P(\omega = k^* \mid \mathbf{X}_t, \mathbf{V}_t) \geq P_{\max}$  alors
21    $\left[ \right.$  retourner  $k^*$ ;
22 sinon
23    $\left[ \right.$  retourner  $\Omega_t^{(\rho)}(P_{\min})$ ;

```



FIGURE 6.4 – Bases de données utilisées pour la reconnaissance avec 4, 8 et 12 classes.

6.4 ÉVALUATIONS

Dans cette section, le cadre multi-échelles pour la planification et la reconnaissance active est évalué à travers une série d'expérimentations sur plusieurs bases de données de véhicules de taille croissante.

6.4.1 Dispositif expérimental et modélisation des objets

Le dispositif expérimental, identique à ceux des chapitres précédents, est décrit à la section 3.3. Le déplacement de l'agent visuel s'effectue sur un degré de liberté permettant une sélection des CPDV selon l'azimut (figure 3.5). Trois bases de données, de taille croissante, ont été considérées pour la reconnaissance afin d'évaluer le comportement de l'algorithme proposé avec l'évolution du nombre de classes. Ces bases sont représentées à la figure 6.4. La taille maximale de la base (douze classes) est certes très inférieure aux bases de données qualifiées d'importantes pouvant atteindre plusieurs dizaines de classes ([LeCun et al., 2004; Everingham et al., 2010]). Néanmoins, l'étude sur les bases considérées permet d'apporter une validation du concept établi, sans interdire l'utilisation de bases plus importantes. La modélisation des objets pour la reconnaissance est réalisée par une approche générative associée au descripteur GLOH [Mikolajczyk et Schmid, 2005]. Leur mise en œuvre est décrite à la section 3.1. Les paramètres des modèles sont identiques à ceux des chapitres précédents pour permettre une comparaison des approches. Le nombre de modes des modèles de vraisemblance est fixé à $M = 14$ et la dimension finale des descripteurs est fixée à $d = 5$.

Critères de performance

Les critères de performance liés à cette approche sont similaires à ceux de l'interprétation pleine échelle (cf. section 2.4.3), mais des comportements spécifiques sont attendus dans le cas multi-échelles. Ils sont ici précisés :

- *Performance maximale* ($Perf_{\max}$) : elle représente le taux moyen d'interprétations correctes atteint après T observations. Il correspond à la performance cumulée moyenne à $t = T$. Ce critère doit être non seulement le plus élevé possible, mais doit être également d'autant plus élevé que l'échelle d'interprétation est grossière (i.e. ρ est grand), ce qui traduit le compromis précision-confiance.
- *Nombre moyen d'observations* (T_{moy}) : il correspond à la moyenne (en nombre d'observations) de la courbe de performance cumulée. Ce critère, qui vérifie $(T + 1)/2 < T_{\text{moy}} \leq T$, doit être le plus faible possible. Il doit également être d'autant plus faible que l'échelle d'interprétation est grossière (i.e. ρ est grand), traduisant le

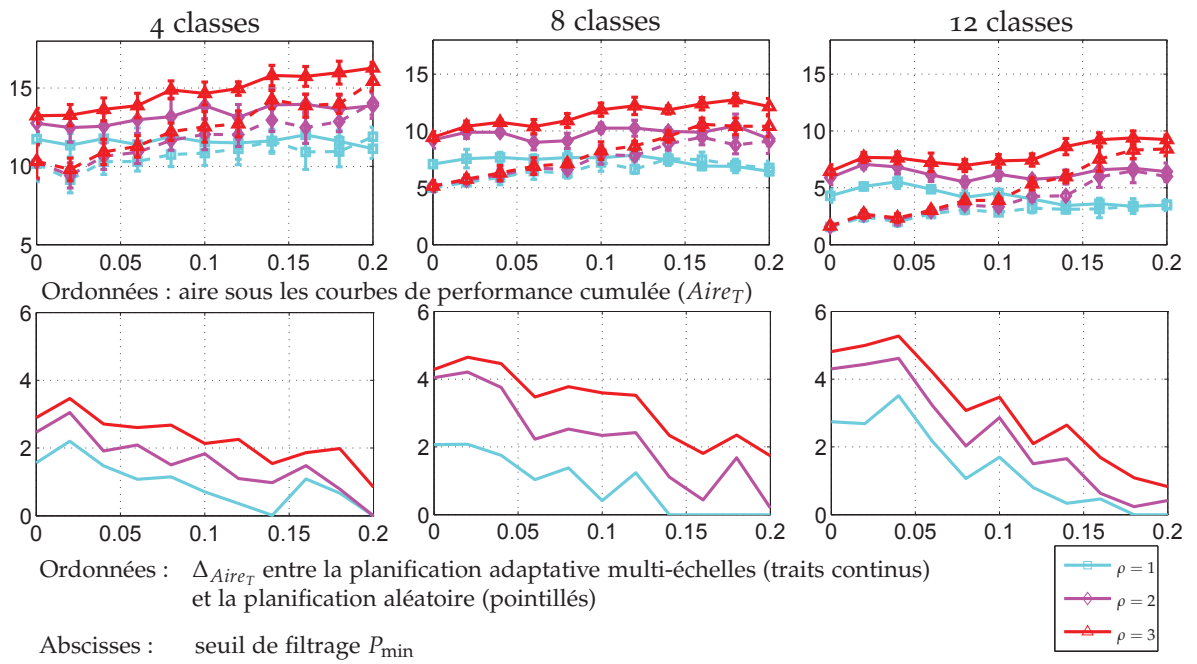


FIGURE 6.5 – En haut : évolution des aires sous les courbes de performance cumulée ($Aire_T$) (cf. figure 6.7) en fonction du seuil de filtrage P_{\min} pour plusieurs échelles d'interprétation ρ . Traits continus : avec planification adaptative multi-échelles ; Traits pointillés : avec planification aléatoire ; en bas : différence entre les courbes continues et les courbes en pointillés.

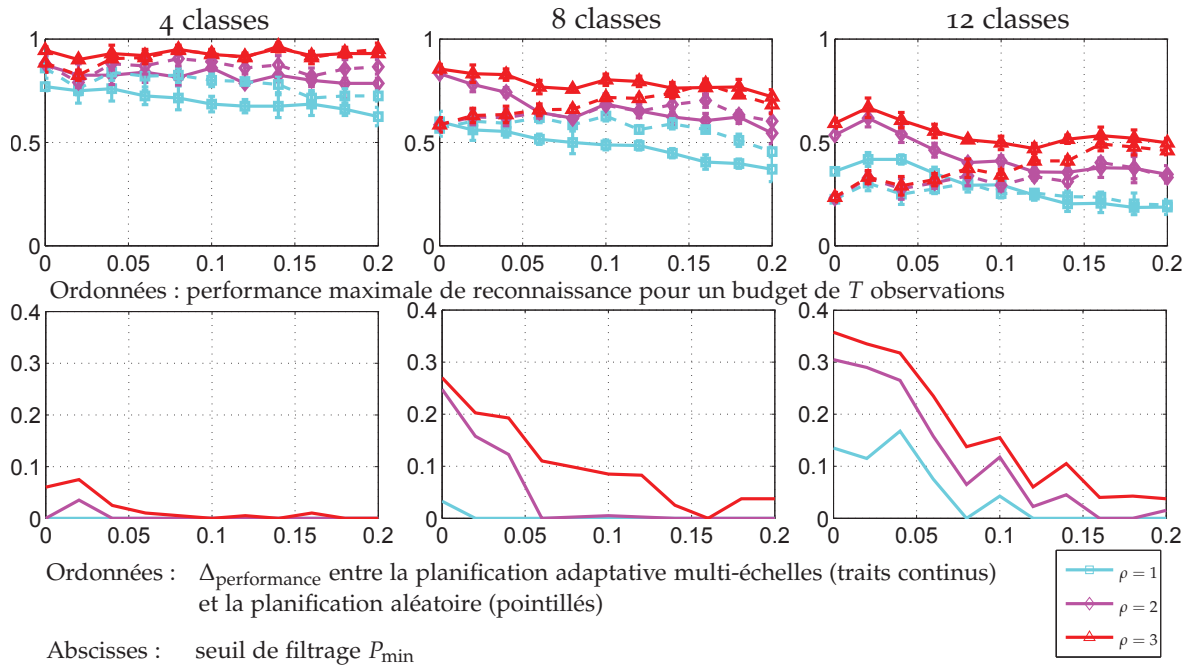


FIGURE 6.6 – En haut : évolution des performances maximales en fonction du seuil de filtrage P_{\min} pour un budget d'observation $T \leq 20$ et pour plusieurs échelles d'interprétation ρ . Traits continus : avec planification adaptative multi-échelles ; Traits pointillés : avec planification aléatoire ; en bas : différence entre les courbes continues et les courbes en pointillés.

compromis entre la quantité d'information et la précision de l'interprétation.

- *Aire sous la courbe de performance cumulée* ($Aire_T$) : synthèse des deux critères précédents, il doit être le plus élevé possible pour une échelle ρ donnée (i.e. égale à $T - 1$), et d'autant plus grand que ρ est faible.

Le choix optimal du seuil de filtrage P_{\min} est également étudié. L'optimalité est définie relativement aux critères de performance précédents. Bien que les valeurs admises pour P_{\min} soient en théorie conditionnées à la taille de la base de données (équation 6.4), des valeurs de P_{\min} plus grandes que $1/\mathcal{K}$ sont en pratique possibles sans risquer l'élimination de l'ensemble des classes. La condition est de commencer le filtrage après l'interprétation de la première observation. De cette manière, les probabilités a posteriori ne sont plus identiques (i.e. sont différentes de $1/\mathcal{K}$) et ne risquent pas d'être toutes inférieures à P_{\min} .

Planification aléatoire

Une planification aléatoire associée à la classification hiérarchique a également été mise en œuvre et comparée avec la planification AME. Elle consiste, au moment de sélectionner les prochaines CPDV, à remplacer la politique de planification par une loi uniforme sur l'espace \mathcal{V} .

6.4.2 Première analyse : apport de l'interprétation multi-échelles

Une reconnaissance multi-échelles a tout d'abord été réalisée dans le but d'évaluer la pertinence d'une interprétation intermédiaire par rapport au rejet. Dans ce but, l'échelle d'interprétation ρ est choisie supérieure à 1 et le seuil P_{\max} est fixé à 1. La reconnaissance est terminée dès que l'échelle Ω_ρ est atteinte. Si le cadre de discernement final contient la classe de l'objet, l'interprétation est correcte. Dans le cas contraire, ou bien lorsque les T observations ne suffisent pas à atteindre l'échelle ρ , l'interprétation échoue.

Performances

La figure 6.5 illustre les performances de reconnaissance pour trois échelles d'interprétation ($\rho=1, 2$ et 3) par le biais du paramètre $Aire_T$ pour un budget de $T = 20$ observations. Plusieurs phénomènes peuvent être relevés :

- Pour ρ et P_{\min} fixés, $Aire_T$ est d'autant plus grand que le nombre de classes de la base est faible, dû à une discrimination plus aisée.
- La figure 6.5, première ligne met en évidence une augmentation de $Aire_T$ lorsque l'échelle d'interprétation augmente (i.e. lorsque ρ diminue). Cette augmentation a lieu quel que soit le seuil de filtrage P_{\min} et quelle que soit la taille de la base de données. Elle traduit une augmentation des performances au détriment de la précision de l'interprétation, ce qui est le comportement attendu de la classification hiérarchique.
- La figure 6.5, deuxième ligne, montre que quel que soit ρ , l'amélioration de $Aire_T$ par rapport à la planification aléatoire est d'autant plus grande que le nombre de classes est élevé. Ce phénomène est particulièrement visible pour des valeurs faibles de P_{\min} . Il traduit le bénéfice de l'approche hiérarchique face à l'écueil du nombre de classes élevé souligné à la section 6.2.
- Enfin, la supériorité de la planification adaptative multi-échelles par rapport à la planification aléatoire est mise en évidence (figure 6.5, deuxième ligne), et ce quel que soit ρ . Cette supériorité est particulièrement visible pour des valeurs faibles de P_{\min} . Pour P_{\max} proche de 0,2, l'amélioration apportée est en revanche plus faible, voire nulle.

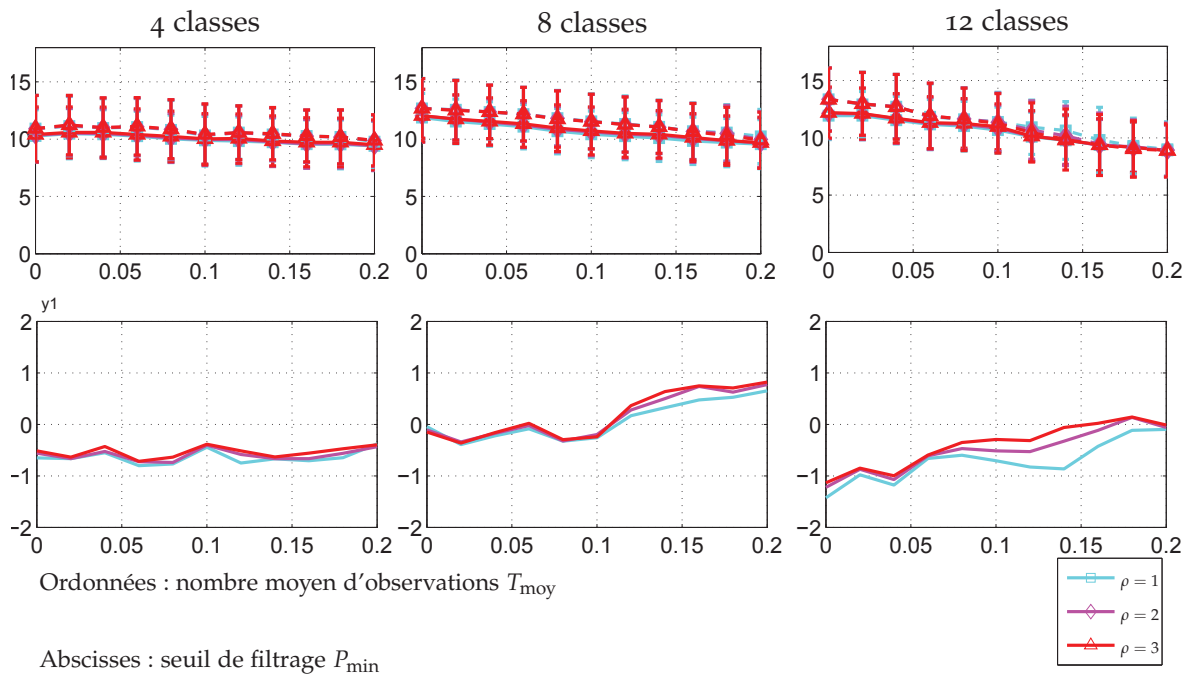


FIGURE 6.7 – En haut : évolution du nombre moyen d'observations T_{moy} pour une interprétation correcte en fonction du seuil de filtrage P_{min} pour plusieurs échelles d'interprétation ρ . Traits continus : avec planification adaptative multi-échelles ; Traits pointillés : avec planification aléatoire ; en bas : différence entre les courbes continues et les courbes en pointillés.

Ces mêmes comportements sont également visibles pour le critère $Perf_{max}$. Ils sont illustrés par la figure 6.6. Ici encore, une augmentation de P_{min} conduit à la fois à une baisse de cette performance maximale et à une amélioration qui devient faible ou nulle par rapport à la planification aléatoire. L'évolution du critère T_{moy} , représentée à la figure 6.7, semble en revanche indépendante de la classification hiérarchique. La forte variance des résultats obtenus (figure 6.7, première ligne) ne permet de conclure ni à une amélioration par la planification adaptative multi-échelles, ni à sa corrélation avec P_{min} . Une faible décroissance est néanmoins visible, ce qui est cohérent avec la faible croissance de $Aire_T$ et la stabilité de $Perf_{max}$.

La figure 6.8 illustre les courbes de performance cumulée pour plusieurs échelles d'interprétation et pour un seuil $P_{min} = 0,06$. Elle confirme le comportement bénéfique de l'interprétation multi-échelles : pour un budget d'observation donné, la performance est d'autant plus élevée que l'échelle est grossière (figure 6.8, première ligne). Pour ρ fixé, le gain apporté par cette approche est d'autant plus grand que la taille de la base de données augmente (figure 6.8, deuxième ligne). Pour cette valeur de filtrage, la planification adaptative multi-échelles est d'un avantage certain sur la planification aléatoire.

6.4.3 Deuxième analyse : apport de la classification hiérarchique pour l'interprétation pleine échelle

Une deuxième série d'expérimentations a été effectuée pour évaluer les performances d'une interprétation pleine échelle en utilisant la hiérarchie de classification définie. Contrairement à l'analyse précédente où la reconnaissance était contrôlée par le seuil P_{min} , la planification AME est ici évaluée lorsque l'interprétation est exclusivement réalisée à l'échelle la plus fine : celle de la classe ($\rho = 1$). La reconnaissance est contrôlée par le seuil de décision P_{max} . L'interprétation est correcte si le maximum a posteriori $\max_{\omega} P(\omega | \mathbf{X}_t, \mathbf{V}_t) \geq P_{max}$ et si ce maximum correspond à la classe de l'objet. Le seuil P_{min} est cependant toujours utilisé pour permettre la planification AME. P_{max} a été fixé à 0,95. Des valeurs inférieures sont possibles, mais une confiance exigée trop faible ne justifie

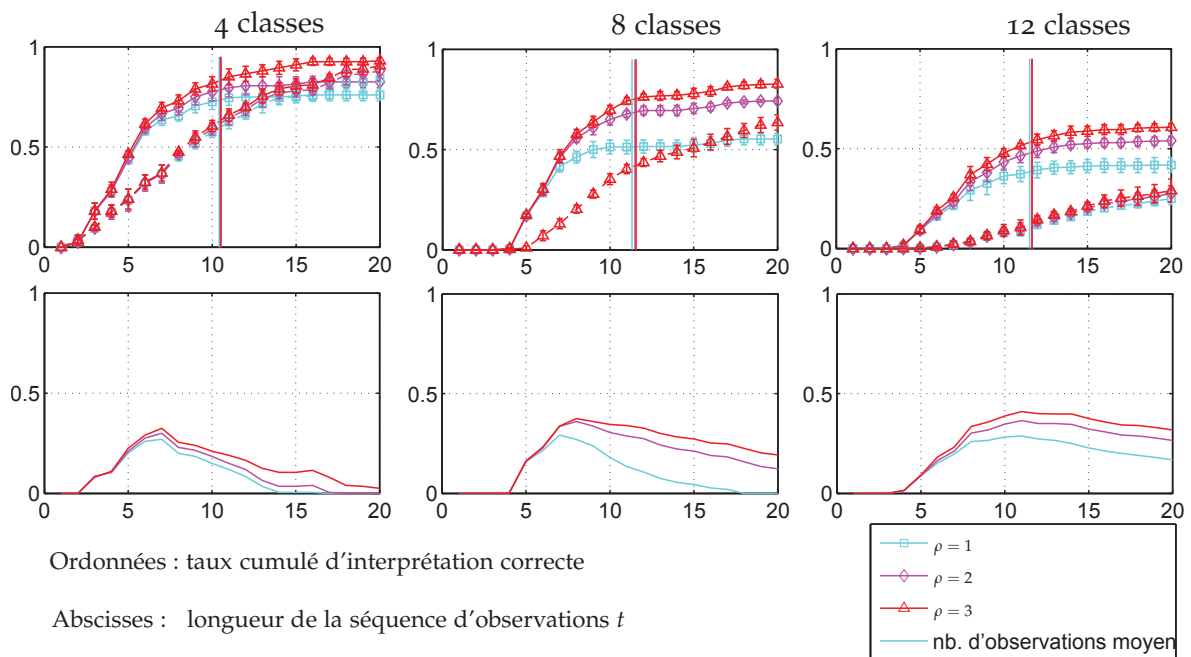


FIGURE 6.8 – En haut : courbes de performance cumulée en fonction du nombre d'observations t pour plusieurs échelles d'interprétation ρ et $P_{\min} = 0,06$. Traits continus : avec planification adaptative multi-échelles; Traits pointillés : avec planification aléatoire; en bas : différence entre les courbes continues et les courbes en pointillés.

pas la mise en œuvre d'une reconnaissance active par rapport à la planification aléatoire (cf. section 4.4).

Performances

L'évolution du paramètre $Aire_T$ en fonction de P_{\min} pour les planifications AME et aléatoire est reportée à la figure 6.9. Trois phénomènes sont mis en évidence :

- Premièrement, l'interprétation pleine échelle est d'autant plus performante que la taille de la base de données est faible. Ce phénomène, également rencontré pour l'interprétation multi-échelles, est dû à la diminution de l'ambiguïté entre les classes lorsque la taille de la base de données diminue (figure 6.9, gauche).
- Deuxièmement, le seuil de filtrage P_{\min} ne modifie pas sensiblement $Aire_T$ pour l'interprétation pleine échelle. De plus, celle-ci reste constante quelle que soit la taille de la base. La classification hiérarchique et la planification AME sont donc sans conséquence sensible sur ce critère de performance.
- La figure 6.9 (à droite) met enfin en évidence la supériorité de la planification AME par rapport à la planification aléatoire. Pour des valeurs faibles de P_{\min} , cette supériorité est d'autant plus grande que le nombre de classes de la base est élevé. La planification AME est donc préférable pour l'interprétation pleine échelle lorsque le nombre de classes est élevé. Ce dernier phénomène est également visible par le critère $Perf_{\max}$ (figure 6.10, gauche). Lorsque P_{\min} augmente jusqu'à 0,2, la performance maximale obtenue avec la planification AME décroît jusqu'à des valeurs égales, voire inférieures à celles obtenues par la planification aléatoire. Pour ce critère comme pour $Aire_T$, le choix de valeurs faibles pour P_{\min} est à privilégier lorsque le budget d'observations est supérieur à $t = 10$. Le choix optimal de P_{\min} (relativement à la performance cumulée) en fonction du budget d'observations est visible à la figure 6.10, droite.

Les résultats pour le critère T_{moy} sont reportés à la figure 6.11. La supériorité de la planification AME par rapport à la planification aléatoire est également visible par ce critère : la planification AME conduit à une reconnaissance en un nombre d'observations plus faible

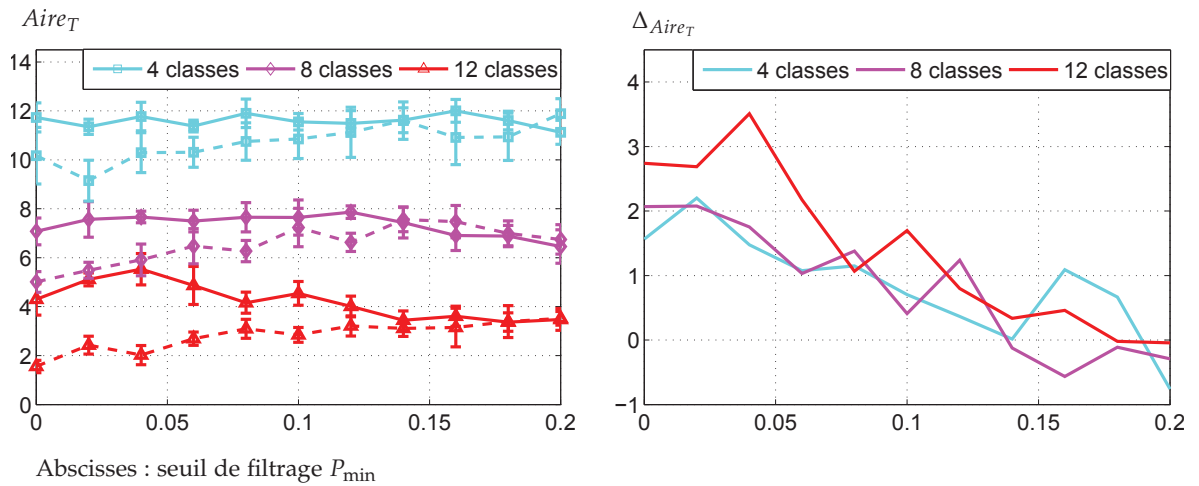


FIGURE 6.9 – À gauche : évolution des aires sous les courbes de performance cumulée ($Aire_T$) (cf. figure 6.12) en fonction du seuil de filtrage P_{min} pour $P_{max} = 0,95$. Traits continus : avec planification adaptative multi-échelles ; Traits pointillés : avec planification aléatoire ; à droite : différence entre les courbes continues et les courbes en pointillés.

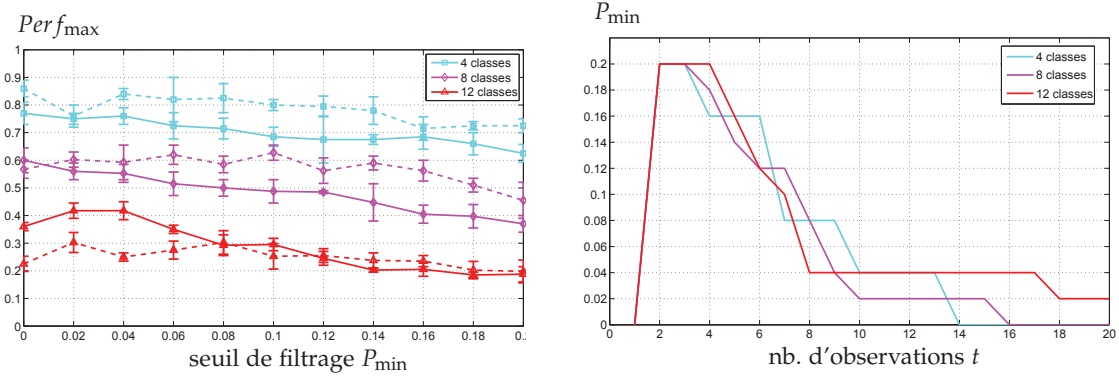


FIGURE 6.10 – À gauche : évolution de la performance maximale (après $T = 20$ observations) en fonction du seuil de filtrage P_{min} ($P_{max} = 0,95$). Traits continus : avec planification adaptative multi-échelles ; Traits pointillés : avec planification aléatoire ; à droite : évolution du seuil de filtrage P_{min} optimal (i.e. maximisant la performance de reconnaissance cumulée) en fonction du nombre d'observations.

en moyenne que pour la planification aléatoire. De plus, l'augmentation de P_{min} réduit sensiblement T_{moy} . Le filtrage est donc bénéfique pour ce critère. Le choix de P_{min} résulte donc d'un compromis entre T_{moy} et la performance maximale. Ce compromis est visible sur les courbes de performance cumulée, figure 6.12, quelle que soit la taille de la base de données.

Un exemple de reconnaissance multi-échelles est illustré par la figure 6.13. Le filtrage progressif des classes engendre une modification des cartes de planification pour les hypothèses restantes et l'apparition de nouvelles CPDV informatives qui sont capturées par la planification AME.





FIGURE 6.11 – À gauche : évolution du nombre moyen d'observations T_{moy} en fonction du seuil de filtrage P_{min} pour une interprétation pleine échelle correcte ($P_{max} = 0,95$). Traits continus : avec planification adaptative multi-échelles; Traits pointillés : avec planification aléatoire; à droite : différence entre les courbes continues et les courbes en pointillés.



Ordonnées : taux de reconnaissance cumulé

Abscisses : longueur de la séquence d'observations t

FIGURE 6.12 – Courbes de performance cumulée en fonction du nombre d'observations (obtenues par moyenne sur l'ensemble des classes de la base) pour plusieurs valeurs du seuil de filtrage P_{min} . Les valeurs du critère T_{moy} sont également représentées.

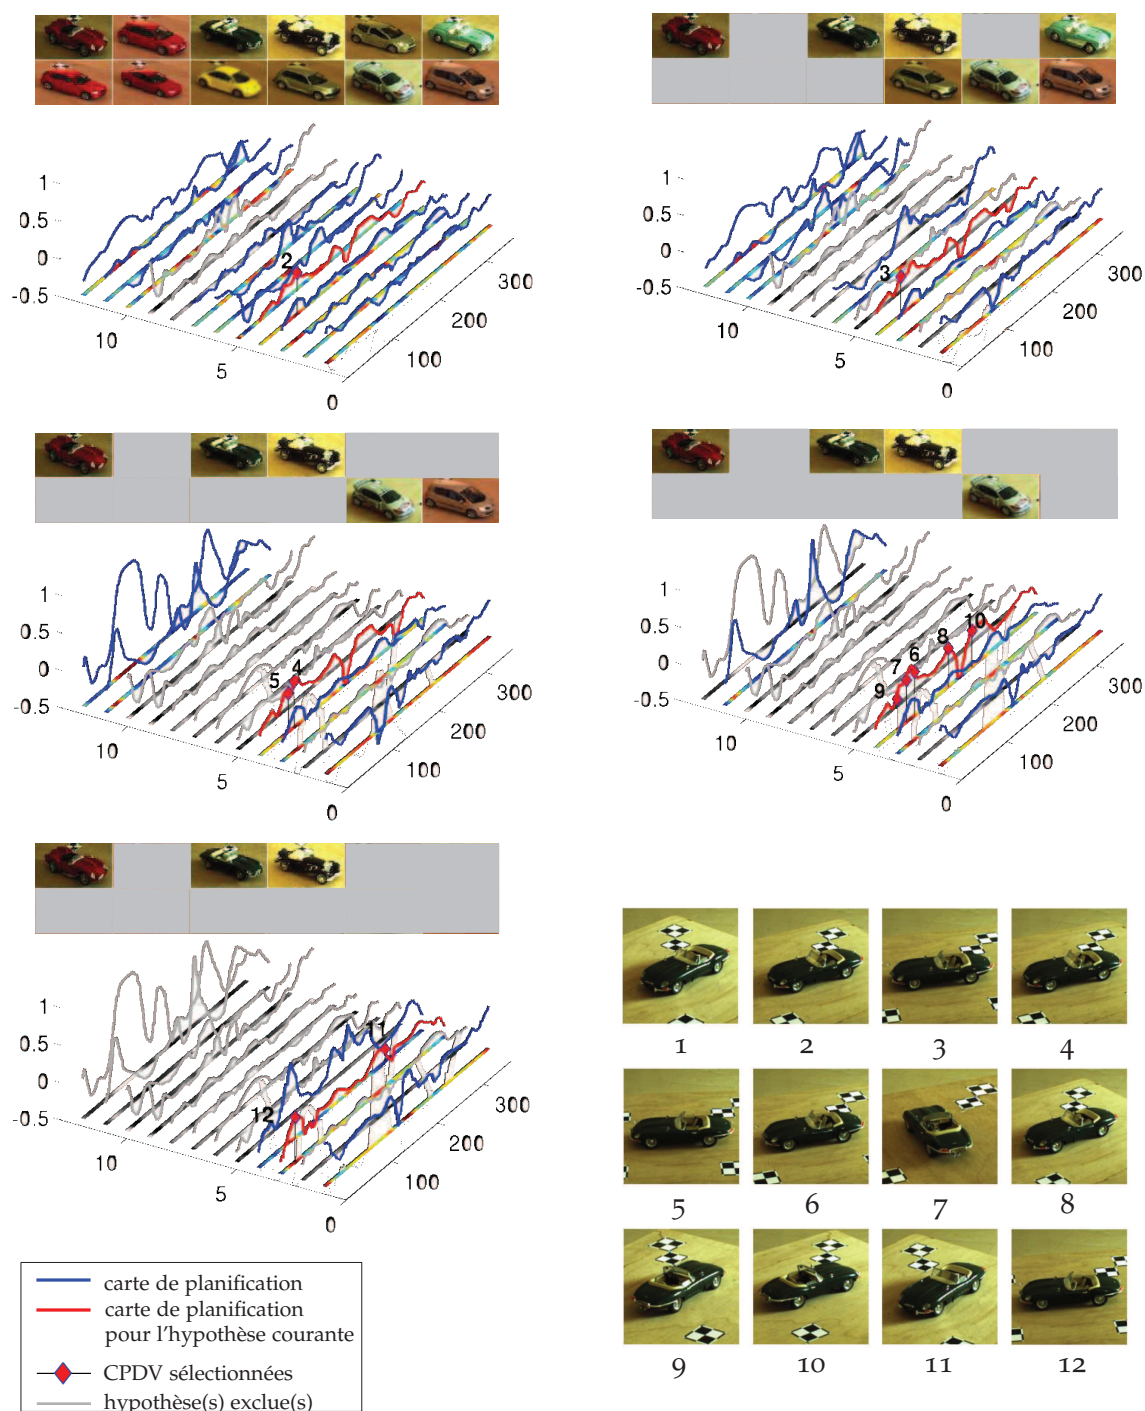


FIGURE 6.13 – Exemple de reconnaissance active multi-échelle avec une planification AME. La première observation est acquise aléatoirement. Après chaque observation, les prochaines CPDV sont sélectionnées à l'aide de la carte de planification courante (en rouge). Les cartes de planification grisées correspondent aux hypothèses exclues du cadre de discernement (dans cet exemple, $P_{\min} = 0,06$).

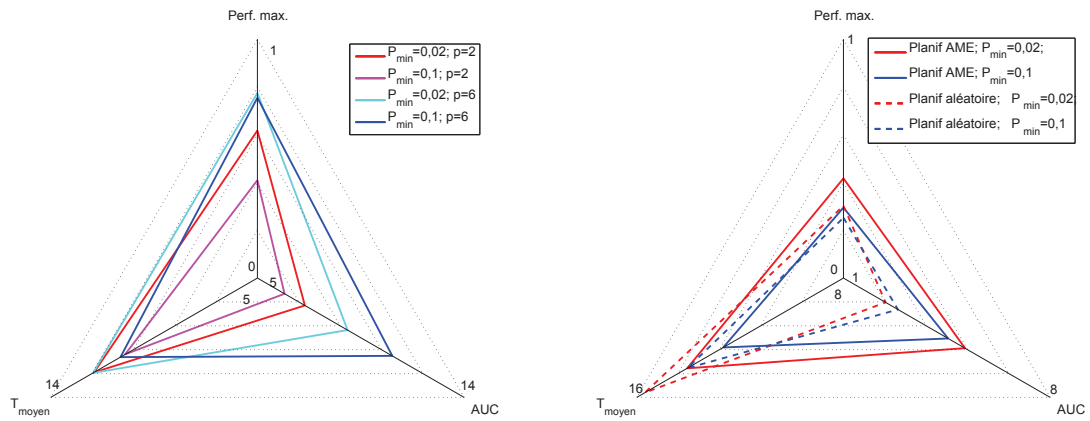


FIGURE 6.14 – Résumé : évolution des trois critères de performance considérés en fonction du seuil de filtrage P_{\min} (exemple avec la base de données de huit classes); à gauche : influence de P_{\min} et de ρ pour l'interprétation multi-échelles ; à droite : influence de P_{\min} pour l'interprétation pleine échelle.

6.4.4 Résumé : choix du seuil P_{\min}

La figure 6.14 résume le comportement des trois critères de performance étudiés en fonction du seuil de filtrage P_{\min} pour la base de données de huit classes. Ces comportements étant antagonistes, la valeur optimale de ce seuil dépend avant tout du compromis recherché. Cependant, les résultats expérimentaux obtenus permettent de conjecturer des valeurs préférentielles de ce paramètre. Un seuil élevé ($>0,1$) conduit à une baisse de T_{moy} , mais à la baisse simultanée de la performance maximale. Cela signifie que lorsque t est plus faible, une performance cumulée supérieure est obtenue avec un seuil de filtrage élevé, mais lorsque la quantité d'observations disponibles est importante ($T = 20$ ici), un seuil plus faible devrait être choisi pour obtenir une performance maximale plus élevée. La figure 6.10, droite, résume également le choix préférentiel de P_{\min} en fonction du nombre d'observations. Une interprétation possible de cette évolution est liée à l'évolution des probabilités a posteriori avec le nombre d'observations. Les premières observations, les plus informatives, permettent une discrimination forte des classes. Un seuil de filtrage élevé est donc bénéfique car le MAP correspond généralement à la classe de l'objet. Mais les observations suivantes sont susceptibles d'être moins informatives, et peuvent conduire à un MAP qui ne correspond plus à la classe de l'objet. Un filtrage élevé peut donc entraîner plus souvent l'élimination à tort de la classe de l'objet.

6.5 DISCUSSIONS

La classification hiérarchique, associée à la planification AME, est une approche nouvelle en reconnaissance active. Les expériences réalisées ont mis en évidence les avantages de cette association. D'une part, le taux de rejet est diminué en contrepartie d'une précision d'interprétation relâchée. D'autre part, le choix du seuil de filtrage P_{\min} est issu d'un compromis entre les différents critères de performances considérés. Ce compromis est fonction du nombre d'observations t . Cette marge de manœuvre est particulièrement avantageuse pour la reconnaissance active car le budget d'observations disponibles est fortement dépendant de la tâche à réaliser.

L'approche multi-échelles proposée possède néanmoins des limitations. La première d'entre elles concerne la planification AME. Pour une base de données de \mathcal{K} classes, elle nécessite la construction de $2^{\mathcal{K}} - \mathcal{K}$ ensembles de critères de planification adaptatifs. La taille de ces ensembles dépend du niveau dans le GAO de planification. Cela revient à calculer $\sum_{k=2}^{\mathcal{K}} \binom{\mathcal{K}}{k} k$ critères de planification (tels que (6.7) ou (6.8)) où $\binom{\mathcal{K}}{k}$ est le nombre de combinaisons de k classes parmi \mathcal{K} . Bien que l'ensemble de ces critères soit calculé hors

ligne (seule la sélection est réalisée en ligne), l'explosion combinatoire du nombre de critères avec le nombre de classes requiert à la fois du temps et une ressource en mémoire suffisante. Notons toutefois que l'apprentissage des politiques de planification peut être effectué de manière parallèle. Chaque observation d'une classe ω permet en effet d'actualiser simultanément tous les nœuds du graphe de planification où ω intervient.

Un autre aspect non pris en compte par cette approche est la possibilité d'un filtrage de classe non définitif. Cela consisterait à permettre le retour dans le cadre de discernement d'une classe éliminée lorsque les observations suivantes infirment la décision de rejet. Ce filtrage non définitif, qui pourrait permettre de diminuer encore le taux de rejet erroné et l'erreur de classification, reste une piste à explorer.

CONCLUSION DU CHAPITRE

Ce chapitre a mis en évidence qu'une interprétation multi-échelles en reconnaissance active est possible et permet de diminuer le taux de rejet lorsque la confiance requise en l'interprétation pleine échelle est élevée. Deux contributions ont été apportées. Dans la première, un graphe acyclique de classification contenant l'ensemble des méta-classes possibles a été proposé. Il permet une organisation autonome de la hiérarchie par le classifieur. La seconde contribution permet de mettre à profit l'aspect "actif" de la reconnaissance dans ce cadre hiérarchique. Pour cela, une stratégie de planification multi-échelles couplée à la hiérarchie de classification a été proposée. Elle permet de capturer l'émergence des CPDV utiles au fur et à mesure de la réduction du cadre de discernement. Les expériences réalisées sur des bases de données de véhicules de tailles différentes ont montré un avantage sensible de l'approche multi-échelles lorsque le nombre de classes de la base augmente. Cette technique de classification supervisée appliquée à la reconnaissance active se révèle bénéfique pour l'interprétation.

Dans le chapitre suivant, nous appliquerons également une classification supervisée pour estimer la position de l'agent visuel à chaque observation (ie. les CPDV des objets), jusque-là supposée connue.

RÉSUMÉ

<i>Positionnement</i>	<ul style="list-style-type: none"> · Reconnaissance active d'objets par le contrôle des CPDV. · Exploitation plus efficace des observations au cours de la reconnaissance pour limiter le rejet, en particulier lorsque le nombre de classes est élevé.
<i>Contributions</i>	<ul style="list-style-type: none"> · Définition d'une nouvelle hiérarchie de classification autonome par filtrage de classes permettant une interprétation provisoire après chaque observation sans relâcher la confiance. · Étude de l'influence du seuil de filtrage sur les performance de reconnaissance. · Nouvelle stratégie de planification des CPDV adaptée à la hiérarchie d'interprétation. Le filtrage progressif des classes fait apparaître des CPDV informatives qui sont capturées en ligne. · Utilisation du critère de sélection max-adaptatif défini au chapitre 4 compatible avec une modélisation imparfaite des objets.
<i>Limitations</i>	<ul style="list-style-type: none"> · Un nombre de classes plus important (supérieur à 12) permettrait de conforter le bénéfice de l'approche. · Le nombre de critères à calculer pendant l'apprentissage est très combinatoire avec le nombre de classes de la base de données, requérant une ressource mémoire suffisante. · Un filtrage non définitif des classes pourrait permettre de diminuer davantage l'erreur de classification.

CLASSIFICATION D'ASPECT ET SÉLECTION DE CARACTÉRISTIQUES POUR UNE ADAPTATION DE DOMAINE

7

Ce chapitre s'intéresse à une caractéristique essentielle d'un algorithme de reconnaissance active, qui est de permettre à l'agent visuel d'évaluer de manière autonome sa position relativement à l'objet afin de se placer dans les CPDV planifiées. Cette caractéristique a été admise dans les chapitres précédents, associée à un modèle d'incertitude sur la pose de l'objet. La mesure des modalités d'acquisitions, en particulier les CPDV, permet notamment à l'agent de reconnaître de manière robuste malgré une évolution dynamique de la scène. Dans ce chapitre, une estimation automatique de la pose de l'objet à chaque observation est proposée et analysée. En particulier, une stratégie par classification supervisée d'aspects est adoptée. Deux contributions sont apportées. Dans la première, la nature du couple descripteur-classifieur, ainsi que la complexité de description est analysée empiriquement à l'aide de données de bases de véhicules réalistes. Dans la deuxième contribution, le problème de généralisation du classifieur, inhérent à l'apprentissage supervisé, est abordé par une nouvelle approche d'adaptation de domaine. Cette approche permet de généraliser le classifieur sur une base de données cible n'ayant pas été utilisée pour l'apprentissage, sans réitérer l'effort d'annotation réalisé dans la base source. L'adaptation est basée sur une sélection d'un sous-ensemble de caractéristiques du descripteur associé à une récente mesure de similarité non paramétrique pour contrôler le processus : Tree-Rank. Elle permet l'utilisation d'une grande variété de descripteurs et de classifieurs sur des données réelles et en grande dimension ($>10\ 000$). Son évaluation pour la classification d'aspects de véhicules, ainsi qu'une comparaison avec une récente technique d'adaptation de domaine, le DASVM, est effectuée et analysée.

PLAN DU CHAPITRE

Ce chapitre est organisé de la manière suivante. Dans la première partie (section 7.1), plusieurs descripteurs et classifieurs sont analysés pour la classification d'aspect. Après un état de l'art sur les différentes techniques d'estimation de la pose des véhicules à la section 7.1.1, plusieurs descripteurs et classifieurs sont présentés à la section 7.1.2 et différents niveaux de complexité de description sont envisagés et évalués à la section 7.1.3. La deuxième partie du chapitre (section 7.2) présente la nouvelle approche d'adaptation de domaine des classifieurs. Le contexte de l'apprentissage transféré, ainsi qu'une définition précise de l'adaptation de domaine sont d'abord donnés aux sections 7.2.1 et 7.2.2. La procédure de sélection de caractéristiques est ensuite décrite à la section 7.2.3. Celle-ci est associée à une mesure de similarité entre deux distributions qui est abordée à la section 7.2.4. L'évaluation de l'adaptation de domaine à l'aide de plusieurs couples descripteur-classifieurs est réalisée à la section 7.2.6, et les discussions sont reportées à la section 7.3.

7.1 ESTIMATION DE LA POSE DES OBJETS

7.1.1 Rappels de l'état de l'art

Comme décrit par la figure 2.2, la reconnaissance active d'objets 3D consiste en une boucle fermée entre la mesure dans la scène et la prise de décision. Mais une boucle d'asservissement entre les CPDV planifiées et celles réellement atteintes par l'agent est également nécessaire. Ce dernier doit en effet être capable de se placer de manière cohérente avec la stratégie de planification mise en œuvre. Cependant, plusieurs difficultés naissent d'une estimation de la pose de l'objet. D'une part, l'estimation doit être indépendante de la classe et nécessite le choix d'un descripteur adapté. D'autre part, seule une information visuelle statique de l'objet est considérée. L'estimation de la pose doit pouvoir être obtenue à partir d'une observation.

Outre la reconnaissance active, l'estimation de la pose est une problématique essentielle liée à la reconnaissance d'objets 3D par classification supervisée à partir d'images. La variabilité d'apparence liée aux changements de pose est importante, et l'apprentissage d'un classifieur intégrant cette variabilité intra-classe est souvent inefficace [Tarr et al., 1998; LeCun et al., 2004]. De nombreuses approches ont été proposées pour estimer la pose des objets d'intérêt préalablement à leur reconnaissance.

- Une première catégorie repose sur une modélisation 3D permettant une inférence simultanée de la classe et de la pose, comme abordée à la section 1.3.3. C'est le cas de l'approche "basée modèle", où un modèle géométrique, généralement polyédrique, est projeté sur l'image puis apparié avec les caractéristiques de l'objet (tels que des contours ou des points d'intérêt). La transformation (rotation 3D, homothétie, translation, . . .) appliquée au modèle pour l'appariement permet d'extraire l'information de la pose de l'objet. La simplicité des modèles géométriques permet d'envisager des modèles génériques pour des catégories d'objets, notamment des catégories de véhicules [Lowe, 1991; Koller et al., 1993; Kollnig et Nagel, 1995; Worrall et al., 1994]. [Tan et al., 1994] proposent, dans le cas des véhicules, une extraction de caractéristiques géométriques très simples permettant une estimation de la pose unique pour l'ensemble des classes. Cependant, l'appariement des modèles est confronté à une combinatoire importante et nécessite le calcul de la transformation à chaque tentative d'appariement. Des informations a priori pour réduire la combinatoire et le temps de calcul peuvent être exploitées, comme la calibration de la caméra pour estimer la distance de l'objet [Tan et al., 1994], la restriction de l'appariement à des poses plausibles [Koller et al., 1993], ou encore un placement du modèle partiellement manuel

[Marchand et Chaumette, 1999]. De tels a priori sur la scène ne sont pas considérés ici, car une autonomie complète de l'agent est recherchée.

- Un appariement entièrement autonome d'un modèle géométrique a été suggéré par [Li et al., 2009] à partir de l'apprentissage de caractéristiques locales d'apparence sur les sommets du modèle associé à une recherche efficace d'appariement. Cet apprentissage nécessite cependant une phase d'annotation très laborieuse (entre 10 et 14 descripteurs locaux placés manuellement sur 1200 images) qui n'est pas envisagée ici.
- Une modélisation d'apparence, par le biais des variétés géométriques d'apparence [Nayar et al., 1996], permet également d'inférer simultanément la pose des objets et leur classe par une mesure de distance entre l'observation et le modèle (i.e. la variété). Les performances de cette stratégie pour inférer la pose des objets sont cependant, comme pour l'inférence de la classe, liées à la qualité des modèles. Comme cela a été considéré au chapitre 4, la modélisation adoptée dans cette thèse, inspirée des variétés géométriques d'apparence, est imparfaite et ne permet pas de discriminer systématiquement les objets pour l'ensemble des CPDV. L'estimation de la pose par cette méthode serait confrontée aux mêmes difficultés. Une estimation robuste de la pose de l'objet à partir de plusieurs observations, comme dans [Mei et al., 2009], pourrait s'avérer efficace, mais elle n'est pas envisagée car une connaissance de la pose dès la première observation est nécessaire.
- Citons enfin l'utilisation de modèles mixtes (ou modèles de constellations, cf. section 1.3.3) qui, en combinant des descripteurs d'apparence locaux des objets et des contraintes géométriques entre ces derniers, permettent une modélisation 3D capable d'extraire la pose d'une nouvelle observation en plus de la classe de manière robuste au bruit de mesure et aux occultations [Savarese et Fei-Fei, 2007; Thomas et al., 2009; Arie-Nachimson et Basri, 2009; Farhadi et al., 2009]. La généralisation des modèles à une catégorie d'objets est cependant une difficulté de cette approche, en particulier pour la catégorie des véhicules [Savarese et Fei-Fei, 2007]. [Arie-Nachimson et Basri, 2009] tentent de pallier cette difficulté par le biais d'un apprentissage séquentiel, en intégrant progressivement l'ensemble des classes dans le modèle pour contrôler la bonne généralisation de celui-ci.

Dans ce chapitre, un découplage entre l'estimation de la pose et de la classe est adopté. Cela permet tout d'abord une intégration directe de l'estimation de la pose dans le formalisme et la modélisation définis aux chapitres 2 et 3. Cela permet également l'utilisation de descripteurs et de classifieurs dédiés pour garantir une performance d'estimation élevée et constante dès la première observation. Une stratégie d'estimation par l'apprentissage supervisé d'un classifieur est utilisée. Cet apprentissage est en particulier réalisé pour la classification d'aspect des véhicules. Les classes sont ici définies par des intervalles de CPDV, formant des aspects (la définition des aspects est ici arbitraire et diffère de la définition topologique de [Koenderink et Doorn, 1979]). La figure 7.6 illustre les aspects définis pour les véhicules. La variabilité d'apparence au sein d'un aspect est apprise par le classifieur sans nécessiter de procédure particulière comme pour les modèles de constellation. Bien que la précision de l'estimation (l'intervalle moyen entre 2 aspects) soit inférieure aux approches précédentes (en particulier celle d'une modélisation structurelle), aucun a priori, comme la calibration de la caméra, n'est nécessaire. L'annotation de chaque aspect est de plus très simple. Ces avantages rendent cette approche attractive, et plusieurs travaux récents la mettent en œuvre sur des bases de données de véhicules [Ozuysal et al., 2009; Rybski et al., 2010].

La généralisation du classifieur est avant tout recherchée. Pour cela, d'une part, plusieurs combinaisons descripteur-classifieur sont évaluées, et une recherche empirique de la complexité optimale des descripteurs est menée (section 7.1.2). D'autre part, la capacité d'adaptation à une autre base de données similaire mais indépendante du processus

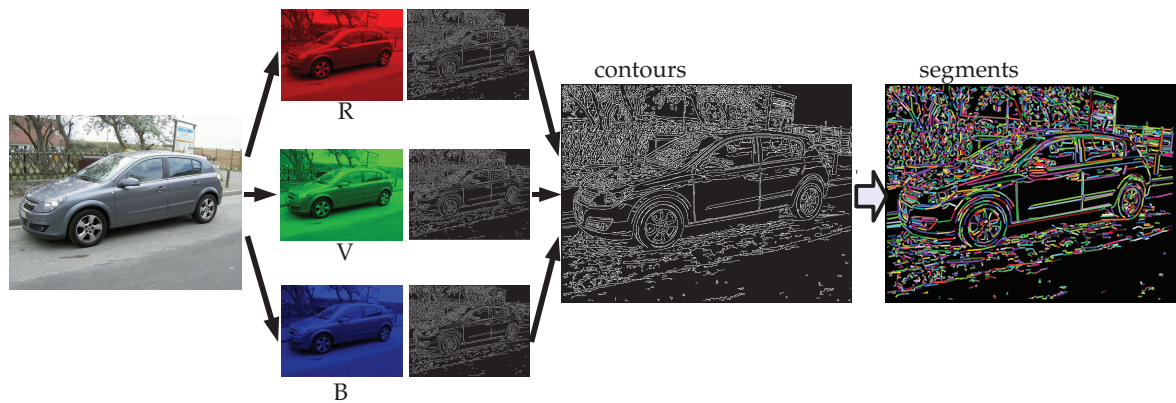


FIGURE 7.1 – Description des images par segments de contour.

d'apprentissage est recherchée. Cette adaptation de domaine du classifieur est abordée à la section 7.2.

7.1.2 Classification d'aspect

La classification d'aspect adoptée dans ce chapitre suppose que l'objet d'intérêt est présent sur l'image. Cela implique une étape préalable de détection qui est en dehors du cadre de cette étude. Le lecteur pourra néanmoins se référer à la section 3.1.1 pour une bibliographie des principaux travaux sur la détection, notamment pour les véhicules. La classification d'aspect, comme tout problème de classification d'images, nécessite le choix à la fois d'un descripteur et d'un classifieur adaptés. Plusieurs stratégies de description sont considérées. Elles sont décrites ci-après.

Descripteurs

Une grande variété de descripteurs d'images pour la classification existent (cf. section 1.3 pour une bibliographie des principales stratégies de description). Chacun d'eux offre des propriétés d'invariance et de robustesse spécifiques. La capacité à capturer la variance inter-classes tout en diminuant la variance intra-classe dépend non seulement de sa nature mais aussi de sa complexité. Dans le cas des véhicules, des surfaces localement planes délimitées par des contours rectilignes rendent un descripteur global basé sur l'orientation des gradients adapté [Li et al., 2008; Rybski et al., 2010]. La capture de surfaces homogènes, caractéristiques des véhicules, par un descripteur d'apparence peut également s'avérer efficace [Ozuysal et al., 2009]. Par ailleurs, une représentation par histogrammes est susceptible d'offrir une robustesse accrue aux variations intra-classe [Swain et Ballard, 1991; Schiele et Crowley, 1996]. Sur la base de ces constatations, trois stratégies de description sont considérées. La complexité du descripteur, qui est un paramètre indépendant de sa nature, joue également un rôle dans les propriétés finales de la représentation. Elle est abordée ensuite.

Segments de contour. Le premier descripteur considéré est basé sur les contours de l'objet. Il consiste à capturer la silhouette de celui-ci par une statistique sur la disposition des contours. Les contours sont ici représentés par une collection de segments de longueur et d'orientation variées. Le processus d'extraction est illustré par la figure 7.1. Il consiste en la succession de deux étapes principales : (i) une extraction des contours par l'algorithme de Canny [Canny, 1987], et (ii) une extraction des segments à partir des contours par l'algorithme de la corde [Ramer, 1972]. La disposition des segments est ensuite capturée par un histogramme d'occurrence quantifiant à la fois l'orientation absolue (par rapport à l'abscisse du repère image) des segments en N_δ cases et leur longueur en N_l cases. En




FIGURE 7.2 – Description par segments de contour et représentation de l'image par un histogramme.

particulier, en notant N_{SEG} le nombre de segments extraits, l'image est représentée par l'ensemble $\{(l_k, \delta_k)\}$, $k = 1, \dots, N_{\text{SEG}}$, où l_k et δ_k sont respectivement la longueur et l'orientation absolue du segment k . Notons que la longueur initiale (en pixels) d'un segment est normalisée par la largeur de l'image pour rendre la description invariante par changement de résolution. Chaque case $x[i, j]$ de l'histogramme descripteur est définie par

$$x[i, j] = \frac{\sum_{k=1}^{N_{\text{SEG}}} \mathbf{1}_{\{(i-1)n_\delta \leq \delta_k \leq in_\delta\}} \mathbf{1}_{\{(j-1)n_l \leq l_k \leq jn_l\}}}{N_{\text{SEG}}}, \quad i = 1, \dots, N_\delta, \quad j = 1, \dots, N_l \quad (7.1)$$

n_l et n_δ sont les pas de quantification respectivement de l et de δ , tels que $l \in [0, 1]$ et $\delta \in [0, \pi]$ ($n_\delta = \frac{\pi}{N_\delta}$ et $n_l = \frac{1}{N_l}$). Le principe de la description par segments de contour et de leur quantification est illustré par la figure 7.2.

Segments adjacents. La deuxième stratégie de description est également basée sur les segments de contour de l'objet. Cependant, ce sont les paires de segments qui sont cette fois considérées. Le nombre de paires étant plus important que le nombre de segments, davantage d'information utile pour la classification est susceptible d'être capturée. Ce descripteur est inspiré des segments adjacents de [Ferrari et al., 2008], mais la contrainte d'adjacence n'est pas considérée ici. Le nombre de paires de segments est noté N_{PAIRES} tel que $N_{\text{PAIRES}} = \binom{N_{\text{SEG}}}{2}$. La disposition des paires est capturée par un histogramme quantifiant la distance entre les milieux des segments en N_η cases et l'angle relatif entre les segments en N_δ cases. Une fois les segments de contour obtenus (cf. la description par segments précédente), l'image est représentée par l'ensemble $\{(\eta_k, \Delta\delta_k, l_1(k), l_2(k))\}$, $k = 1, \dots, N_{\text{PAIRES}}$. η_k est la distance en pixels (normalisée par la largeur de l'image) entre les milieux des deux segments de la paire k , $\Delta\delta_k$ est l'angle relatif entre les segments, et $l_1(k)$ et $l_2(k)$ sont les longueurs normalisées des segments. Chaque case $x[i, j]$ de l'histogramme descripteur est définie par

$$x[i, j] = \frac{\sum_{k=1}^{N_{\text{PAIRES}}} l_1(k)l_2(k) \mathbf{1}_{\{(i-1)n_\delta \leq \Delta\delta_k \leq in_\delta\}} \mathbf{1}_{\{(j-1)n_\eta \leq \eta_k \leq jn_\eta\}}}{\sum_{k=1}^{N_{\text{PAIRES}}} l_1(k)l_2(k)}, \quad i = 1, \dots, N_\delta, \quad j = 1, \dots, N_\eta \quad (7.2)$$

n_η et n_δ sont les pas de quantification respectivement de η et de $\Delta\delta$, tels que $\eta \in [0, 1]$ et $\Delta\delta \in [0, \pi]$ ($n_\delta = \frac{\pi}{N_\delta}$ et $n_\eta = \frac{1}{N_\eta}$). Le principe de la description est résumé par la figure 7.3.

Vocabulaire visuel. La description d'une image par un vocabulaire visuel, ou sac de mots¹, a été suggérée par [Csurka et al., 2004]. Les résultats obtenus par les auteurs ont montré une robustesse du descripteur aux objets parasites de la scène et de bonnes performances de reconnaissance sans même utiliser l'information géométrique de l'image. Cette stratégie a été initialement appliquée à la catégorisation d'images [Csurka et al., 2004; Lazebnik et al., 2006]. Elle est ici mise en œuvre pour la classification de la pose des véhicules. La description d'une image est basée sur un histogramme du nombre d'occurrences

1. De l'anglais : *bag of words* ou *bag of keypoints*.




FIGURE 7.3 – Description par paires de segments de contour et représentation de l'image par un histogramme.

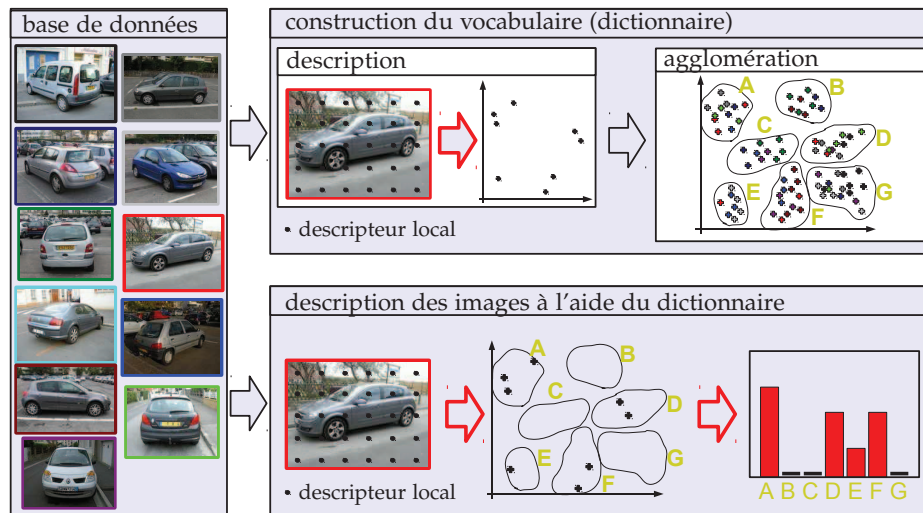


FIGURE 7.4 – Description des images par un vocabulaire visuel.

des mots d'un dictionnaire visuel. La construction du dictionnaire est réalisée en deux étapes. La première consiste à extraire des images d'apprentissage un ensemble de descripteurs d'apparence locale. Ces descripteurs sont ensuite agglomérés dans la deuxième étape (l'algorithme K -means est utilisé ici), chacun des agglomérats formant un mot visuel. La description d'une nouvelle image est également réalisée en deux étapes : (i) une extraction de descripteurs d'apparence locale similaire à la phase d'apprentissage, puis (ii) la construction de l'histogramme d'occurrence des mots du dictionnaire construit lors de l'apprentissage. Une manière courante de construire l'histogramme d'occurrence (qui est adoptée dans les expérimentations qui suivent) est de considérer, dans l'espace de représentation, la distance de chaque descripteur local de l'image aux centroïdes des agglomérats. Une occurrence est alors attribuée aux deux mots les plus proches, en proportion inverse de leur distance. Le principe de la description par vocabulaire visuel est illustré par la figure 7.4. La dimension finale du descripteur est égale à la taille du dictionnaire, (ou au nombre d'agglomérats considérés, K). Le choix d'une répartition des descripteurs locaux sur une grille régulière dans l'image permet, contrairement aux descripteurs précédents, de capturer également des zones non saillantes des objets.

Complexité de la description

Les propriétés recherchées pour le descripteur - une forte variance inter-classes et une faible variance intra-classe - pour conduire à une erreur de classification faible (se référer à la section 1.3.1) sont également gouvernées par la complexité de la description. Une trop faible complexité (par exemple le descripteur constant) ne permet pas de discriminer les classes, alors qu'une complexité trop forte peut conduire à une mauvaise généralisation du classifieur. Pour une nature de descripteur donnée, la recherche de ces propriétés implique

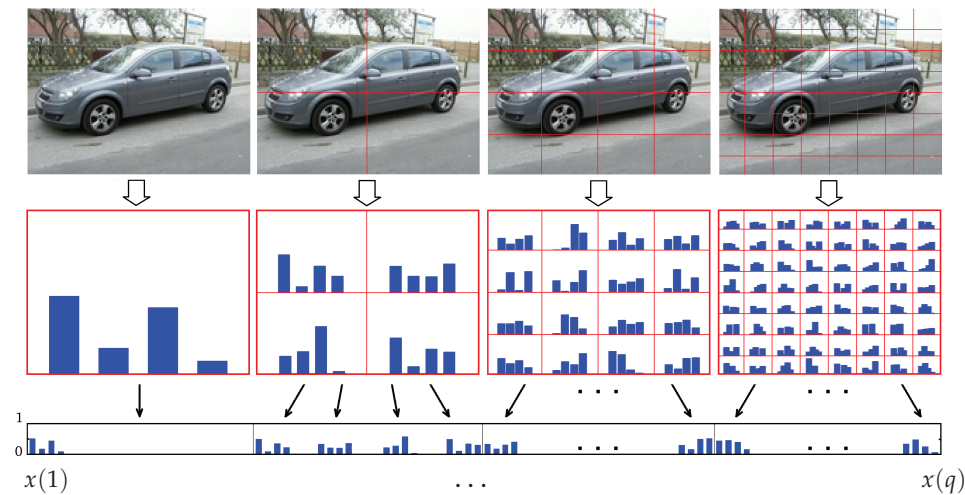


FIGURE 7.5 – Représentation spatiale pyramidale des images et description par histogrammes.

une recherche de la complexité optimale.

La complexité est définie de deux manières : la complexité de quantification d'une part et la complexité spatiale d'autre part.

La complexité de quantification est définie par le nombre de niveaux de quantification des histogrammes - N_δ et N_l dans la description par segments de contour; N_δ et N_η dans la description par paires de segments; K (le nombre de mots du dictionnaire) dans la description par vocabulaire visuel. Le niveau de complexité de quantification est contrôlé par le paramètre $N_{\text{quantif.}}$.

La complexité spatiale permet quant à elle d'exploiter l'information géométrique de l'objet pour la représentation. Une stratégie efficace consiste à introduire l'information géométrique par le biais d'une pyramide spatiale de représentation [Lazebnik et al., 2006; Bosch et al., 2007; Tola et al., 2008]. Le premier niveau de la pyramide représente l'image originale. Le niveau n consiste en un découpage de l'image sur une grille régulière de taille $2^{n-1} \times 2^{n-1}$ ($n = 1, \dots, N_{\text{spatial}}$). La figure 7.5 illustre le principe. L'histogramme final de représentation est obtenu par la concaténation des histogrammes de chacune des cases de la pyramide, conduisant à un vecteur de représentation de dimension q . La complexité spatiale est contrôlée par le nombre de niveaux N_{spatial} de la pyramide. Les niveaux de complexité de quantification $N_{\text{quantif.}}$ et leur correspondance avec la dimension des différents descripteurs, sont résumés par la table 7.1.

$N_{\text{quantif.}}$	1	2	3	4	5
$N_l \times N_\delta / N_\eta \times N_\delta$	2×4	4×8	6×12	8×16	10×20
K (taille du dictionnaire)	50	100	150	200	250

TABLE 7.1 – Les différentes complexités de quantification des descripteurs et dimensions des histogrammes correspondantes.

Classification

Les descripteurs d'images étant obtenus, deux techniques de classification, SVM et boosting, sont considérées en association avec chacun des descripteurs précédents. Leur principe est décrit ci-après.

SVM. Les SVMs ou machines à vecteurs supports [Vapnik, 2000] consistent à déterminer un hyperplan dans l'espace de description qui sépare deux classes avec une marge maxi-

male. La marge est définie par la distance entre l'hyperplan et le point d'apprentissage le plus proche. Étant donnée une observation x associée à un label $\omega = \pm 1$, le classifieur est défini par :

$$f(x) = \text{sign}(w^T x + b) \quad (7.3)$$

où w, b représentent les paramètres de l'hyperplan. La résolution du problème de maximisation de la marge conduit à une solution pour w de la forme $\hat{w} = \sum_i \hat{v}_i \omega_i x_i$ où les \hat{v}_i sont les coefficients du Lagrangien primal estimés à l'aide des données d'apprentissage (x_i, ω_i) , tel que $0 \leq \hat{v}_i \leq \lambda$. Les x_i pour lesquels $\hat{v}_i \neq 0$ sont appelés vecteurs supports. Lorsque les données ne sont pas linéairement séparables, le SVM peut être appris à l'aide d'une mesure de distance non linéaire dans l'espace de représentation. Cela revient à effectuer une projection des données de l'espace initial vers un nouvel espace à l'aide d'une fonction $\varphi(\cdot)$. L'avantage du SVM est que cette projection peut être formulée entièrement en termes de produit scalaire dans le nouvel espace, défini par le noyau

$$k(u, v) = \varphi(u)\varphi(v) \quad (7.4)$$

L'équation (7.3) est alors ré-écrite par :

$$f(x) = \text{sign} \left(\sum_i \omega_i v_i k(x, x_i) + b \right) \quad (7.5)$$

Le paramètre de réglage de la procédure est λ , qui traduit la régularisation de la fonction f . Une valeur importante encourage les variations fortes de f et le sur-apprentissage. Au contraire, une faible valeur de λ engendre des variations plus lentes de $f(\cdot)$ et une frontière plus lisse. Les paramètres du noyau, lorsqu'il y en a, ainsi que le paramètre de régularisation λ , sont généralement estimés par validation croisée.

Boosting. Le boosting est une procédure d'apprentissage dans laquelle un ensemble de classifieurs faibles (i.e. dont le taux d'erreur reste inférieur à celui du classifieur aléatoire, mais peut être proche) sont rassemblés en un comité formant un classifieur fort. Le premier algorithme par boosting, appelé AdaBoost, a été proposé par [Schapire et al., 1998]. Il a depuis évolué et différentes déclinaisons sont aujourd'hui disponibles. L'une d'elles, qui est celle adoptée dans ce chapitre, est appelée GentleBoost ou Gentle AdaBoost [Friedman, 1998]. L'apprentissage est basé sur l'optimisation d'une fonction de perte exponentielle par une méthode de Newton à pas adaptatifs. La procédure est résumée par l'algorithme 9. La

Algorithme 9: GentleBoost

Entrées : données d'apprentissage $\{(x_i, \omega_i)\}$, $i = 1, \dots, N$, nombre d'itérations I

Sorties : classifieur $f(\cdot)$

- 1 initialisation des poids $w_i = 1/N$, $i = 1, \dots, N$;
 - 2 $k=0$;
 - 3 **répéter**
 - 4 apprendre le classifieur faible $f_k(x)$ sur les x_i (pondérés par les w_i) par moindres carrés avec les ω_i ;
 - 5 actualiser $w_i \leftarrow w_i e^{-\omega_i f_k(x_i)}$ et normaliser tel que $\sum_{i=1}^N w_i = 1$;
 - 6 **jusqu'à** $k = I$;
 - 7 Classifieur final $f(x) = \sum_{k=1}^I f_k(x)$;
-

principale différence entre GentleBoost et AdaBoost réside dans la restriction de l'intervalle de valeurs possibles des classifieurs faibles $f_k(\cdot)$. Ici, $f_k(x) = P_w(\omega = 1 | x) - P_w(\omega = -1 | x)$, qui appartient à l'intervalle $[-1, 1]$ alors que le log-ratio $f_k(x) = \frac{P_w(\omega=1|x)}{P_w(\omega=-1|x)}$, utilisé par AdaBoost, peut s'avérer numériquement instable [Friedman, 1998].

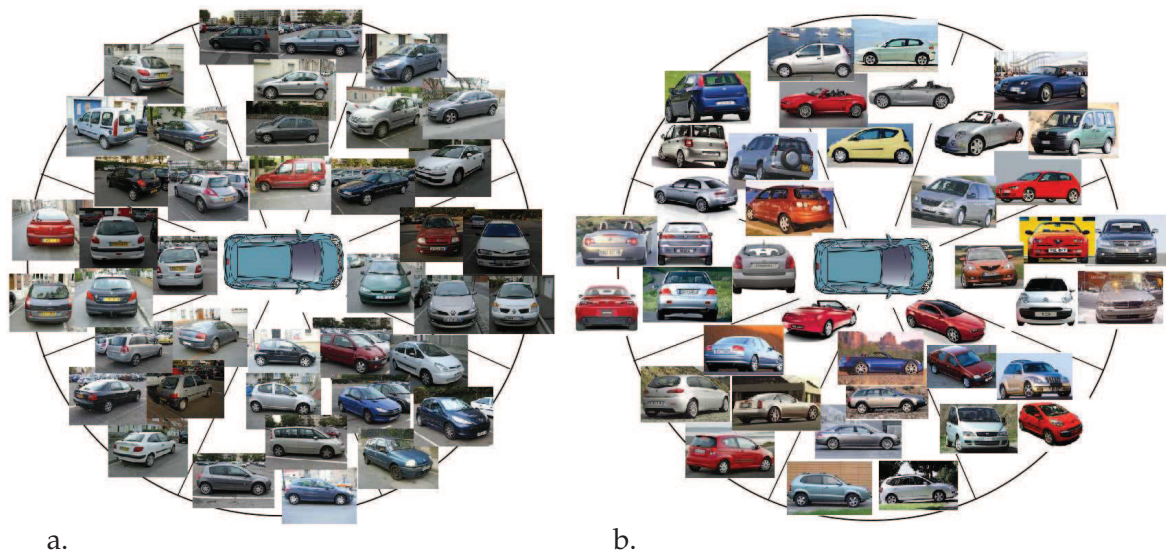


FIGURE 7.6 – Illustration des bases de données de véhicules pour la classification d'aspects. a. : base source (annotée); b. : base cible (non annotée).

7.1.3 Évaluations

Une première série d'évaluations a été effectuée pour évaluer les propriétés des descripteurs et des classifieurs considérés précédemment. Les bases de données utilisées sont constituées d'images de véhicules (tous modèles confondus) et sont illustrées par la figure 7.6. La mise en évidence de plusieurs phénomènes est recherchée. D'une part, une étude empirique de l'influence de la nature du couple descripteur-classifieur et de la complexité (spatiale et de quantification) des descripteurs est réalisée. D'autre part, la capacité d'adaptation du couple descripteur/classifieur est examinée. L'adaptation reflète la capacité du classifieur à donner des performances constantes sur des bases de données similaires mais n'ayant pas été utilisées lors de l'apprentissage. Elle est vue comme une capacité de généralisation au-delà de l'erreur de test sur la base d'apprentissage.

Bases de données

Deux bases de données ont été considérées. Le classifieur est appris uniquement sur une base source annotée (figure 7.6.a), et les performances de généralisation sur cette base ont tout d'abord été évaluées. Puis les performances sur une base cible (figure 7.6.b), contenant les mêmes classes mais indépendante du processus d'apprentissage, ont été mesurées. La différence entre les deux bases provient uniquement de l'origine des données. Pour la base source, celles-ci ont été acquises en milieu urbain tandis que les images de la base cible sont issues de divers sites internet. Les bases source et cible contiennent respectivement 1663 et 2098 images. Chaque image a une résolution de 160×120 pixels.

Paramètres des descripteurs

L'extraction des segments de contour intervenant dans les descripteurs par segments et par paires de segments a été obtenue par l'algorithme de la corde [Ramer, 1972]. La figure 7.7 illustre le principe d'extraction des segments. Un contour est récursivement divisé en segments (ou cordes) jusqu'à ce que sa distance maximale à la corde ϵ soit inférieure à un seuil. Une étape de fusion et de filtrage a ensuite été effectuée. Deux segments sont fusionnés si leur distance minimale d_{\min} est en dessous d'un seuil d_{fusion} et si l'angle relatif $\Delta\delta$ entre les deux segments est inférieur à $\Delta\delta_{\text{fusion}}$. Les segments obtenus ayant une longueur l inférieure à un seuil l_{\min} ont ensuite été éliminés. Dans les expérimentations, ces paramètres ont été fixés à $d_{\text{fusion}} = 2$ pixels, $\Delta\delta_{\text{fusion}} = 2$ degrés, et $l_{\min} = 3$ pixels.

La construction du vocabulaire visuel a été réalisée par une description des images sur une grille régulière de pas 5 pixels. En chaque point de la grille, un descripteur SIFT [Lowe, 2004] a été extrait. Celui-ci consiste en une zone de taille 20×20 pixels divisée en 16 blocs. Dans chaque bloc, un histogramme d'orientation du gradient selon huit directions a été extrait, conduisant à un descripteur local de dimension 128. L'intensité des pixels a été




FIGURE 7.7 – Principe d'extraction des segments de contour par l'algorithme de la corde (à gauche) et fusion des segments extraits (à droite).

normalisée avant le calcul du gradient dans le but de rendre la description invariante par changements d'illumination. Notons que cette normalisation ne s'est pas avérée nécessaire pour l'extraction des contours par l'algorithme de Canny.

Réduction finale de la dimension

Une étape de réduction finale de la dimension des descripteurs a été effectuée préalablement à l'apprentissage des classifieurs.

Dans le cas du SVM, la réduction de dimension est basée sur la mesure de l'information mutuelle conditionnelle entre les caractéristiques (les cases de l'histogramme) et les classes. Les d caractéristiques de score maximal sont sélectionnées, d étant la dimension finale du descripteur ($d \leq q$). Le calcul de l'information mutuelle conditionnelle est basé sur l'algorithme CMIM [Fleuret, 2004]. Cet algorithme ne prenant en entrée que des vecteurs binaires, une étape de binarisation des histogrammes a été effectuée sur les données d'apprentissage pour extraire ce classement. Dans le cas de deux classes, les histogrammes de chaque classe ont pour cela été comparés. Plus précisément, en notant $x_i^{(\omega=-1)}$ et $x_i^{(\omega=1)}$ deux histogrammes respectivement de la classe $\omega = -1$ et $\omega = 1$, la i -ième caractéristique binaire $b_i^{(\omega=-1)}$ résultante a été définie par

$$b_i^{(\omega=-1)}[j] = \begin{cases} 1 & \text{si } x_i^{(\omega=-1)}[j] \geq x_i^{(\omega=1)}[j] \\ 0 & \text{sinon} \end{cases}, j = 1, \dots, q \quad (7.6)$$

et $b_i^{(\omega=1)}$ est défini par le complémentaire à 1 de $b_i^{(\omega=-1)}$. Une fois le classement extrait, les d caractéristiques (ou dimensions) de score maximal forment le sous-espace de représentation dans lequel toute nouvelle donnée est projetée.

Dans le cas de GentleBoost, la réduction de la dimension a été effectuée en considérant I classifieurs faibles. Chacun d'entre eux effectue une classification selon une dimension. La dimension et le seuil de décision optimaux sont choisis par l'algorithme de manière à minimiser l'erreur quadratique pondérée de classification.

La valeur $I = d = 100$ a été choisie dans les expérimentations. Notons que cette étape de réduction de dimension n'intervient pas lorsque la dimension initiale du descripteur q est inférieure à cette valeur.

Paramètres des classifieurs

La nature des classifieurs faibles mis en œuvre dans GentleBoost, assurant à la fois la classification et la réduction de dimension, a été décrite au paragraphe précédent. Dans le

	SVM, seg. de contour	SVM, paires de seg.	SVM, sac de mots	GentleBoost, seg. de contour	GentleBoost, paires de seg.	GentleBoost, sac de mots
Perf. max. source	0,82	0,75	0,86	0,73	0,67	0,82
Écart type	0,017	0,014	0,019	0,016	0,003	0,021
$N_{\text{quantif.}}$	2	3	3	1	2	3
N_{spatial}	4	3	4	4	4	4
Perf. max. cible	0,58	0,43	0,60	0,48	0,43	0,21
Écart type	0,012	0,07	0,03	0,001	0,01	0,008
$N_{\text{quantif.}}$	2	2	2	1	2	2
N_{spatial}	4	2	3	4	4	3

TABLE 7.2 – Performances de classification pour plusieurs combinaisons de descripteurs et de classifieurs. Seules les performances maximales sont représentées, ainsi que les niveaux de complexité des descripteurs correspondants.

cas du SVM, l'apprentissage a été réalisée à l'aide du noyau intersection d'histogramme, défini par

$$k(x_1, x_2) = \sum_{j=1}^d \min(x_1[j], x_2[j]) \in [0, 1] \quad (7.7)$$

Ce noyau, non linéaire et non paramétrique, a montré de bonnes performances de classification [Lazebnik et al., 2006] et ne nécessite aucun réglage.

Pour chaque classifieur, son extension au multi-classes a été réalisée par une stratégie *un contre tous* (décrite à la section 1.2.4). \mathcal{K} classifieurs ont été appris (\mathcal{K} étant le nombre de classes), chacun permettant de discriminer la classe k des autres classes. La classification d'une nouvelle donnée a été obtenue par vote majoritaire.

Résultats

Pour chaque niveau de complexité spatiale N_{spatial} et de quantification $N_{\text{quantif.}}$, la performance de l'ensemble des couples descripteur-classifieur a été évaluée sur la base source. Les résultats ont été obtenus par validation croisée d'ordre cinq. La table 7.2 reporte les performances maximales sur la source et la cible (parmi les différents niveaux de complexité) obtenues pour chacun des couples descripteur-classifieur considéré. Les performances source et cible pour l'ensemble des niveaux de complexité du couple sac de mots-SVM sont illustrées par la figure 7.8. Plusieurs constatations peuvent être relevées.

La première d'entre elle est que la nature du descripteur et du classifieur influence sensiblement les performances de classification. Sur les bases de données considérées, le descripteur par sac de mots associé au classifieur SVM conduit aux meilleurs résultats.

Une deuxième constatation est que la complexité du descripteur a également une influence importante. En particulier, une valeur élevée du paramètre N_{spatial} est préférable pour maximiser les performances sur la source. La valeur de $N_{\text{quantif.}}$ semble toutefois moins influente. Comme le montre la table 7.2, la complexité optimale sur la base source est presque toujours supérieure à celle de la cible. Ainsi, une première solution pour garantir une bonne généralisation du classifieur sur la base cible est de choisir convenablement N_{spatial} et $N_{\text{quantif.}}$. La généralisation est cependant au prix d'une légère baisse de performance sur la base source.

Enfin, une troisième constatation est une différence importante de performances entre la source et la cible, quelque soit le couple descripteur-classifieur. L'optimisation seule de la complexité semble insuffisante pour atteindre des niveaux de performance semblables. Pour tenter de résoudre cette difficulté, une nouvelle approche d'adaptation de domaine est proposée à la section suivante.




FIGURE 7.8 – Performances de classification sur la base source et cible pour les différents niveaux de complexité envisagés (descripteur : sac de mots ; classifieur : SVM avec noyau intersection).

	0,81	0,02	0	0	0,11	0,01	0	0,05		0,37	0	0,02	0,01	0,59	0	0,01	0	
	0,03	0,84	0,09	0,01	0,01	0,01	0,01	0		0,05	0,60	0,19	0,02	0,06	0,05	0,02	0,01	
	0,01	0,02	0,89	0,04	0,01	0,02	0,03	0		0,01	0,03	0,82	0,01	0,05	0	0,07	0,01	
	0	0	0,05	0,84	0,06	0,01	0,02	0,02		0,05	0,04	0,22	0,39	0,16	0,02	0,06	0,06	
	0,05	0	0,01	0,01	0,90	0,03	0	0		0,12	0	0,03	0,01	0,81	0,01	0,02	0	
	0,01	0,02	0,01	0	0,03	0,89	0,04	0		0,06	0,05	0,05	0,03	0,16	0,33	0,25	0,07	
	0	0	0,03	0,01	0,02	0,04	0,87	0,03		0,01	0,01	0,01	0	0,02	0,01	0,92	0,02	
	0,04	0,01	0	0,01	0,01	0	0,06	0,87		0,04	0	0,01	0,11	0,11	0,02	0,18	0,53	

TABLE 7.3 – Matrices de confusion pour le couple sac de mots-SVM ; à gauche : sur la base source ($N_{\text{quantif.}} = 3$, $N_{\text{spatial}} = 4$) ; à droite : sur la base cible ($N_{\text{quantif.}} = 2$, $N_{\text{spatial}} = 3$).

7.2 ADAPTATION DE DOMAINE DU CLASSIFIEUR

Dans la section précédente, l'étude de plusieurs descripteurs sur les deux bases de données considérées (figure 7.6) a montré qu'à la fois la complexité spatiale et la complexité de quantification influence les performances de la classification. En particulier, la complexité optimale du descripteur pour la classification de la source diffère (i.e. est supérieure dans les expérimentations) de celle de la cible, ce qui traduit un sur-apprentissage du classifieur sur la base source. De plus, l'optimisation de la complexité à elle seule ne permet pas d'obtenir une performance d'adaptation sur la base cible acceptable au regard des résultats obtenus (table 7.2). Dans cette section, une nouvelle stratégie pour l'adaptation de domaine est proposée et analysée pour améliorer les performances sur la base cible sans réitérer l'effort d'annotation de la base source. Cette stratégie est basée sur une réduction de la dimension initiale des descripteurs par la recherche de caractéristiques communes aux deux bases de données. Elle offre deux avantages majeurs : d'une part, par une recherche de caractéristiques efficace d'un point de vue algorithmique, la méthode proposée peut être appliquée à des bases de données massives et de grande dimension telles que celles considérées dans ce chapitre. D'autre part, l'adaptation est indépendante du choix du descripteur et du classifieur.

7.2.1 Origines de l'apprentissage transféré

L'approche classique pour l'apprentissage supervisé d'un classifieur repose sur la disponibilité d'une riche quantité de données annotées pour assurer une bonne généralisation sur de nouvelles données. Cependant, la performance de généralisation du classifieur repose sur l'hypothèse usuelle que les données de test sont issues de la même distribution sous-jacente que les données d'apprentissage. L'apprentissage transféré² rassemble les techniques mises en œuvre lorsque les deux distributions diffèrent [Pan et Yang, 2010]. La principale question liée à l'apprentissage transféré est de savoir quelle information utiliser et comment l'utiliser pour exporter un classifieur vers d'autres bases de données. La solution la plus simple, mais également la plus coûteuse, serait d'ignorer les données du domaine source et d'apprendre une nouvelle fois le classifieur après l'annotation des données du domaine cible. Le coût d'annotation limite considérablement cette approche. La question d'exploiter l'information déjà acquise en transférant les connaissances du domaine source annoté vers le domaine cible non annoté (ou faiblement annoté) a suscité un intérêt croissant ces dernières années. Les premières méthodes sont apparues à la suite du besoin de généraliser le classifieur lorsque les données d'apprentissage sont peu nombreuses, voire unique pour chaque classe. Cette dernière technique est connue sous le nom d'apprentissage mono-image³. Cet apprentissage transféré peut être réalisé au niveau des données en sélectionnant un jeu de caractéristiques communes aux deux domaines [Torralba et al., 2007; Epshtein et Ullman, 2005b]. D'autres auteurs s'attachent à une modélisation de la variance intra-classe des données [Miller et al., 2000; Martínez, 2002; Fei-Fei et al., 2006], en élaborant des classifieurs invariants à partir d'une connaissance a priori sur les données, comme les techniques des SVMs invariants [Decoste et Schölkopf, 2002], ou encore de manière supervisée en basant l'apprentissage sur une faible quantité de données cibles annotées [Dai et al., 2007; Saenko et al., 2010]. Une troisième approche exploite l'information contextuelle comme un lien entre les domaines source et cible [Rohrbach et al., 2010]. Cependant, ces approches sont généralement restreintes à des descripteurs et des classifieurs spécifiques, par conséquent à des applications spécifiques. De surcroît, elles n'exploitent pas l'information des données cibles non annotées.

Dans la suite de ce chapitre, la nouvelle stratégie d'adaptation de domaine proposée pour la classification d'image est réalisée par la combinaison de deux éléments. Tout d'abord, en exploitant l'information mutuelle entre les données non annotées et les deux domaines, une nouvelle représentation commune et de dimension réduite est extraite. Deuxièmement, la qualité de cette nouvelle représentation est évaluée par une récente mesure de similarité entre deux distributions, appelée TreeRank [Cléménçon et al., 2009] basée sur le test d'homogénéité de Mann-Whitney-Wilcoxon. Les avantages de cette nouvelle approche sont cruciaux au regard de son application pour la classification d'images. D'une part, elle est non paramétrique, i.e. chacun des deux ingrédients peut traiter des données de grande dimension. D'autre part, l'utilisation de descripteurs et d'algorithmes de classification variés est possible. La suite du chapitre est organisée de la manière suivante : la définition exacte de l'adaptation de domaine ainsi qu'une revue des travaux associés est donnée à la section suivante. La réduction de dimension pour l'adaptation est décrite à la section 7.2.3, tandis que la mesure de similarité non paramétrique est présentée à la section 7.2.4. La section 7.2.5 résume la procédure d'adaptation de domaine et les résultats expérimentaux sont présentés à la section 7.2.6. L'ensemble des résultats de ce chapitre est discuté à la section 7.3.

7.2.2 Principe de l'adaptation de domaine et travaux connexes

L'objectif commun de l'adaptation de domaine et de l'apprentissage transféré est de tirer parti des tâches précédentes pour en traiter de nouvelles qui sont différentes mais

2. *Transfer learning.*

3. *One-shot learning.*

connexes, où les données annotées sont peu nombreuses, voire non disponibles. Un domaine est dénoté par $\mathcal{D} = (\mathcal{X}, P)$, où P est une distribution a priori sur un espace de représentation \mathcal{X} . Une tâche est définie de manière similaire à [Pan et Yang, 2010]. Elle consiste en l'apprentissage supervisé d'un classifieur à partir d'un jeu de données fini. Le domaine source est défini par $\mathcal{D}_S = (\mathcal{X}, P_S)$ et les données sources (annotées) par $(\mathbf{X}_S, \omega_S) = \{x_{i,S}, \omega_{i,S}\}_{i=1\dots N_S}$ où $x_{i,S} \in \mathcal{D}_S$ et $\omega_{i,S} \in \Omega$ est la classe correspondante. Des données cibles non annotées, $\mathbf{X}_T = \{x_{i,T}\}_{i=1\dots N_T}$, sont distribuées sur un domaine cible \mathcal{D}_T . \mathcal{D}_S diffère de \mathcal{D}_T par $P_S(x, \omega) \neq P_T(x, \omega)$. Cela implique une possible différence des distributions marginales : $P_S(x) \neq P_T(x)$, ainsi que des distributions conditionnelles $P_S(\omega | x) \neq P_T(\omega | x)$, conduisant au cas particulier de l'adaptation de domaine. Plusieurs travaux ont été réalisés pour résoudre les problèmes d'adaptation de domaine pour une grande variété d'applications. Une première approche consiste à pondérer l'une des deux distributions à partir d'une estimation de densité par un noyau paramétrique [Shimodaira, 2000]. Mais cette technique n'est généralement pas adaptée à des données éparées et de grande dimension. L'adaptation de domaine pour la classification d'images n'a été considérée que plus récemment par les travaux de [Saenko et al., 2010]. L'adaptation est basée sur l'apprentissage supervisé d'une mesure de transformation symétrique entre les deux domaines. [Kulis et al., 2011] ont étendu cette stratégie à des transformations non symétriques permettant une adaptation pour des représentations de dimensions différentes entre les domaines. Cependant, ces méthodes requièrent des données cibles annotées sans tirer parti de l'information apportée par les données non annotées. Une autre technique récente, le DASVM, a été suggérée par [Bruzzone et Marconcini, 2010]. Elle utilise les données cibles non annotées dans une procédure d'estimation itérative des paramètres d'un SVM. Cette approche repose sur une hypothèse de corrélation entre les deux domaines. Pour étendre l'adaptation à des classifieurs variés, une autre approche consiste à rechercher une structure sous-jacente des données non annotées commune aux deux domaines. L'extraction de la structure a été réalisée de plusieurs manières pour des applications à l'origine différentes de la classification d'image. Il s'agit par exemple des caractéristiques pivots [Blitzer et al., 2006] ou des hiérarchies de caractéristiques [Arnold et al., 2008]. La comparaison des structures conduit généralement à une nouvelle représentation des données dans un espace de plus petite dimension. Cette réduction de dimension est d'un grand avantage car elle permet à la fois l'adaptation de domaine et une efficacité calculatoire accrue de l'apprentissage. Plusieurs autres techniques de réduction de dimension ont été proposées pour l'apprentissage transféré et se sont révélées efficaces [Satpal et Sarawagi, 2007; Quattoni et al., 2008; Pan et al., 2009]. Cependant, le point commun de ces approches est le besoin d'une modélisation explicite de la structure des données, comme la co-occurrence avec les caractéristiques pivots [Blitzer et al., 2006], des arbres de hiérarchie [Arnold et al., 2008], ou des métriques de similarités paramétriques [Satpal et Sarawagi, 2007; Quattoni et al., 2008; Pan et al., 2009]. De tels modèles reposent sur des hypothèses fortes sur les données et sont très spécifiques de la tâche à réaliser, conduisant à une faible capacité de réplification de ces méthodes.

La technique d'adaptation de domaine proposée partage le même paradigme d'une réduction de la dimension fondée sur la structure des données. Mais contrairement aux travaux précédents, la comparaison de la structure est directe, sans nécessiter de modélisation explicite. Elle est compatible avec une grande variété de descripteurs et de classifieurs et est particulièrement adaptée à la classification d'images. Le principe de la méthode est décrit ci-après.

7.2.3 Comparaison de la structure des données non annotées

Dans cette section, une représentation des données dans un sous espace permettant une adaptation de domaine est recherchée.

Représentation des données

Étant données les deux bases de données \mathbf{X}_S et \mathbf{X}_T , avec $x \in \mathcal{X} = \mathbb{R}^q$, la fonction de transformation des données recherchée est définie par

$$\begin{aligned} \varphi_p : \mathbb{R}^q &\longrightarrow \mathbb{R}^p, \quad p \leq q \\ x &\longmapsto \varphi_p(x) \end{aligned} \quad (7.8)$$

$\varphi_p(\cdot)$ consiste en la sélection de q dimensions (ou caractéristiques) parmi les d dimensions initiales. Elle peut également être formulée par $\varphi_p(x) = Wx$ où $\dim x = 1 \times q$ et W est une matrice de projection binaire telle que $\dim W = p \times q$. p est le paramètre de cette transformation.

Le cadre d'adaptation de domaine proposé, basé sur une sélection de caractéristiques, repose sur les hypothèses suivantes :

- 1- il existe un sous-ensemble de p caractéristiques vérifiant

$$P_S(\omega \mid \varphi_p(x)) = P_T(\omega \mid \varphi_p(x)) \quad (7.9)$$

- 2- la proportion des classes est conservée d'un domaine à l'autre

$$P_S(\omega) \approx P_T(\omega) \quad (7.10)$$

Cette dernière hypothèse est nécessaire car les données cibles ne sont pas annotées, et un déséquilibre trop important des classes engendrerait une modification de la structure des données même si les distributions conditionnelles étaient identiques. Après la transformation par $\varphi_p(\cdot)$, les propriétés suivantes devraient être vérifiées :

1) $P_S(\varphi_p(x)) = P_T(\varphi_p(x))$, qui traduit l'homogénéité des bases. À partir des hypothèses précédentes, $\varphi_p(\cdot)$ doit également vérifier (7.9). Ces deux égalités signifient que le classifieur doit être aussi performant sur le domaine source que sur le domaine cible, ce qui est l'objectif de l'adaptation de domaine.

2) $\varphi_p(\cdot)$ doit préserver les variances inter-classes et intra-classe dans le domaine source (cf. figure 1.6). En d'autres termes, l'augmentation de l'erreur de classification sur la base source après transformation doit être aussi faible que possible.

Ces deux propriétés sont considérées dans le cadre d'une réduction de la dimension basée sur la théorie de l'information, permettant une comparaison directe des structures de données. Ce cadre est abordé ci-après.

Classement des caractéristiques par l'information mutuelle

Considérons une paire caractéristique-domaine (F, D) comme deux variables aléatoires. F représente la valeur de la caractéristique (ou "feature") d'une donnée quelconque de D (par exemple la valeur d'une case d'un histogramme). Dans notre cas, $F \in \mathbb{R}$ et $D = 1$ ou -1 selon le domaine (source *vs.* cible). L'information mutuelle entre D et F repose sur l'entropie $\mathcal{E}(D)$ qui définit l'incertitude sur la valeur de D . L'incertitude restante sur D lorsque F est connue est donnée par l'entropie conditionnelle $\mathcal{E}(D \mid F)$. L'entropie conditionnelle est étroitement liée à la structure de F , ce qui est une propriété clé pour estimer $\varphi_p(\cdot)$. Si la structure de F d'un domaine à l'autre est inchangée, alors sa connaissance n'apporte rien à la connaissance de D . Dans ce cas, F et D sont indépendants, et l'entropie conditionnelle est égale à l'entropie seule. Au contraire, si F possède une structure spécifique dans chacun des deux domaines, sa connaissance est équivalente à la connaissance de D . dans ce cas, l'entropie conditionnelle est nulle. L'information mutuelle (IM) entre F et D est

$$IM(F, D) = \mathcal{E}(D) - \mathcal{E}(D \mid F) \quad (7.11)$$

Elle représente l'information contenue dans F sur la valeur de D , ce qui constitue un critère adapté pour la comparaison des structures sans avoir à modéliser celles-ci.

L'équation (7.11) permet de déterminer les caractéristiques à écarter pour l'adaptation de domaine : celles dont l'IM est élevée. Le classement induit par cette mesure est noté

$$F_q^{ord.} = \{x(1), \dots, x(q)\} \quad (7.12)$$

tel que $MI(x(i), D) \geq MI(x(j), D) \forall 1 \leq i < j \leq q$

La question de la quantité de caractéristiques à écarter est abordée à la section suivante.

7.2.4 Évaluation de la distance entre deux distributions

Dans cette section, le problème de l'élimination d'un nombre optimal de caractéristiques est abordé. Cela revient à déterminer un compromis entre la performance de classification dans le domaine source (conserver toutes les caractéristiques) et la performance de l'adaptation (ne conserver que les caractéristiques d'IM faibles).

Mesures de similarité

La définition d'une distance ou mesure de similarité entre deux distributions est un problème clé de l'apprentissage transféré. Elle doit permettre de quantifier la similarité entre les distributions (inconnues) P_S et P_T . En d'autres termes, elle doit refléter la performance du classifieur sur le domaine cible étant donnée sa performance sur le domaine source. Pour cela, la mesure doit être globale, c'est-à-dire depuis une échelle grossière jusqu'à une échelle fine des données. Plusieurs métriques ont été utilisées dans le cadre de l'apprentissage transféré, incluant la divergence de Kullback-Leibler (KL) [Dai et al., 2008], ou la discrèpance moyenne minimum (MMD⁴) [Pan et al., 2009]. Cependant, ces outils classiques requièrent le calcul de noyaux paramétriques (pour l'estimation de la densité dans le cas de la divergence KL, et pour une meilleure estimation du maximum dans le cas de la MMD). Des métriques non paramétriques sur des espaces pouvant être de grandes dimensions ont été proposées via l'analyse de Procrustes [Wang et Mahadevan, 2008]. Elles sont basées sur la norme de Frobenius mesurée à l'aide des données disponibles. Cependant, elles reposent sur une hypothèse forte d'appariement des points (des paires de points) entre les deux domaines, même si des travaux ont permis de relâcher un peu cette contrainte, comme dans [Wang et Mahadevan, 2009]. Une distance plus récente, appelée \mathcal{A} -distance, a été suggérée par [Kifer et al., 2004] pour l'adaptation de domaine, mais son calcul est NP-dur. Une approximation de cette distance a été proposée par [Ben-David et al., 2007]. Elle est basée sur un classifieur linéaire entre les données sources et cible, mais ne permet pas de capturer la géométrie locale des données.

Dans la section suivante, la similarité entre deux distributions sur des espaces pouvant être de grande dimension est mesurée par une procédure de classement global des données, conduisant à la même décision statistique et à la même efficacité que le test non paramétrique de Mann-Whitney-Wilcoxon [Cléménçon et al., 2009]. Son principe est maintenant abordé.

Mesure de similarité par l'aire sous la courbe

Considérons un jeu de N paires $(x_i, D_i)_{i=1..N} \in \mathbb{R}^p \times \{-1, 1\}$ où D_i représente le domaine de x_i . Dénotons par $\mathbf{X}_S = \{x_{i,S}\}_{i=1..N_S}$ (resp. $\mathbf{X}_T = \{x_{i,T}\}_{i=1..N_T}$) les données sources (resp. cibles), telles que $N = N_S + N_T$. \mathbf{X}_S est issu de la distribution $P_S(x)$, tandis que \mathbf{X}_T est issu de $P_T(x)$.

Cas mono-dimensionnel ($p = 1$). La similarité entre les distributions P_S et P_T est mesurée en basant la décision sur un classement des données sources parmi l'ensemble des

4. *Minimum Mean Discrepancy.*

données (sources et cibles). Cette similarité est capturée par le critère de l'aire sous la courbe ROC⁵ (AUC⁶) qui est défini ici par

$$\text{AUC}(P_S, P_T) = P(x_S > x_T) + \frac{1}{2}P(x_S = x_T) \quad (7.13)$$

Dans le cas où les distributions sont identiques, $\text{AUC}(P_S, P_T) = \frac{1}{2}$, alors que $\text{AUC}(P_S, P_T) = 1$ dans le cas séparable.

Cas multi-dimensionnel ($p > 1$). Le classement des données est dans ce cas effectué à l'aide d'une fonction de score $s : \mathbb{R}^p \mapsto \mathbb{R}$ dont le comportement est tel que plus $s(x)$ est élevé, plus l'événement " $D = 1$ " devrait être observé. La fonction de score optimale s^* est la distribution conditionnelle réelle (inconnue) :

$$s^*(x) = P(D = 1 \mid x) \quad (7.14)$$

L'AUC obtenue après le classement par s , dénotée AUC_s , est maximisée par s^* . La similarité (7.13) est alors mesurée par $\text{AUC}^* = \text{AUC}_{s^*}$. La principale difficulté réside dans le calcul de s^* . Ce point est abordé à la section 7.2.6

Connexion avec le test d'homogénéité de Mann-Whitney-Wilcoxon

Le grand avantage de l'AUC (7.13) pour mesurer la similarité entre deux distributions est sa capacité à être appliquée à des données de grande dimension. La similarité entre P_S et P_T peut être obtenue quelle que soit la dimension initiale des données à partir de leur score mono-dimensionnel $s^*(x)$, sans compromettre la pertinence du critère. Cette propriété provient du lien avec la statistique de Mann-Whitney qui est exactement la version empirique de l'AUC. Elle est également liée à la somme des rangs, la statistique non paramétrique de Wilcoxon. Une analyse détaillée de cette analogie est disponible dans [Cléménçon et Vayatis, 2009]. Elle n'est pas développée davantage ici car elle n'est pas essentielle au discours.

7.2.5 Résumé de la procédure

La procédure globale pour l'adaptation de domaine, permettant le classement des caractéristiques par l'IM (section 7.2.3) et une sélection selon le compromis classification-adaptation (section 7.2.4) est résumée par l'algorithme 10 dans le cas d'une classification binaire. Celui-ci fournit en sortie une fonction de sélection $\Psi_d(\cdot)$ qui projette les données initiales dans un espace de plus faible dimension qui est bénéfique à la fois pour l'adaptation de domaine et pour la tâche considérée. Des étapes additionnelles nécessaires à son implémentation sont détaillées ci-après.

Réduction ultérieure de la dimension

Aux lignes 3 et 9 de l'algorithme 10, une étape de réduction supplémentaire de la dimension est effectuée pour permettre une plus grande efficacité calculatoire lorsque p est grand. Cela revient à appliquer une transformation supplémentaire $\phi'_d(\cdot)$ telle que

$$\begin{aligned} \phi'_d : \mathbb{R}^p &\longrightarrow \mathbb{R}^d, \quad d \leq p \\ \phi_p(x) &\longmapsto \phi'_d(\phi_p(x)) \end{aligned} \quad (7.15)$$

Cette transformation est indépendante de l'adaptation de domaine. L'objectif est exclusivement la recherche d'un sous-espace dans lequel la variance inter-classe est grande et la variance intra-classe faible dans le domaine source. Elle est réalisée uniquement à partir des données sources. La transformation finale est donnée par $\Psi_d(\cdot) = \phi'_d \circ \phi_p(\cdot)$.

5. Receiver Operating Characteristic.

6. Area Under Curve.

Algorithme 10: Adaptation de domaine dans le cas de deux classes.

Entrées : données sources $\mathbf{X}_S = \{x_{i,S}\}_{i=1\dots N_S}$
données cibles $\mathbf{X}_T = \{x_{i,T}\}_{i=1\dots N_T}$
seuil sur l'AUC AUC_{\min}^*
 $k \geq 1; d$

Sorties : fonction de projection $\Psi_d(\cdot)$

- 1 calculer $F_q^{ord.}$ (éq. (7.11) et (7.12));
- 2 $p = q$;
- 3 calculer $\varphi_p(x_{i,S})$ et $\varphi_p(x_{i,T}) \forall i$; calculer $\varphi'_d(\cdot)$ (éq. (7.15)), puis $\Psi_d(\cdot) = \varphi'_d \circ \varphi_p(\cdot)$;
- 4 calculer AUC^* à partir de $\Psi_d(x_{i,S})$ et $\Psi_d(x_{i,T})$ (sec. 7.2.4);
- 5 **répéter**
- 6 | écarter les k premières caractéristiques de $F_q^{ord.}$;
- 7 | $p \leftarrow p - k$;
- 8 | actualiser $\varphi_p(x_{i,S})$ et $\varphi_p(x_{i,T})$ (éq. (7.12));
- 9 | calculer $\varphi'_d(\cdot)$ (éq. (7.15)), puis $\Psi_d(\cdot) = \varphi'_d \circ \varphi_p(\cdot)$;
- 10 | calculer AUC^* à partir de $\Psi_d(x_{i,S})$ et $\Psi_d(x_{i,T})$ (sec. 7.2.4);
- 11 **tant que** $AUC^* > AUC_{\min}^*$;

Algorithme 11: Extension de l'algorithme 10 au cas multi-classes (*un contre tous*)

- 4 **pour** chaque classe $k \in [1, \dots, \mathcal{K}]$ **faire**
- 4.1 | calculer $\varphi_d^{(k)}(\cdot)$ (éq. (7.15)), puis $\Psi_d^{(k)}(\cdot) = \varphi_d^{(k)} \circ \varphi_p(\cdot)$;
- 5 **pour** chaque classe $k \in [1, \dots, \mathcal{K}]$ **faire**
- 5.1 | calculer $AUC^{*(k)}$ à partir de $\Psi_d^{(k)}(x_{i,S})$ et $\Psi_d^{(k)}(x_{i,T})$ (sec. 7.2.5);
- 5.2 calculer AUC^* (éq. 7.16);

Extension au cas multi-classes

L'application de l'algorithme 10 peut être étendue au cas multi-classes à l'aide des stratégies *un contre tous* ou *un contre un* (cf. section 1.2.4). La stratégie *un contre tous* est détaillée ici (avec \mathcal{K} classes). Dans ce cas, les lignes 3 et 9 sont répétées pour chaque classe, conduisant à \mathcal{K} transformations $\varphi_d^{(k)}(\cdot)$, $k \in [1, \dots, \mathcal{K}]$. Lors de la classification d'une nouvelle donnée, chaque $\varphi_d^{(k)}(\cdot)$ est appliquée pour classifier la classe k vs. les autres, et la classe finale est obtenue par vote majoritaire.

Aux lignes 4 et 10, le calcul de AUC^* est aussi effectué après chaque transformation $\Psi_d^{(k)}(\cdot) = \varphi_d^{(k)} \circ \varphi_p(\cdot)$, conduisant à $AUC^{*(k)}$, $k \in [1, \dots, \mathcal{K}]$. L'AUC finale est obtenue par :

$$AUC^* = \frac{1}{\mathcal{K}} \sum_{k=1}^{\mathcal{K}} AUC^{*(k)} \quad (7.16)$$

Cette extension est résumée par l'algorithme 11.

7.2.6 Évaluations

Dans cette section, une série d'expérimentations a été réalisée pour valider l'approche d'adaptation de domaine proposée. Les conditions expérimentales sont détaillées ci-après.

Dispositif expérimental

Bases de données. Les bases de données utilisées sont les mêmes que dans la section 7.1 et illustrées par la figure 7.6. Rappelons que seules les images du domaine source sont annotées.

Descripteurs. La description des images est abordée à la section 7.1.2. Elle comprend les descripteurs par segments de contour, par paires de segments et par vocabulaire visuel. Une représentation spatiale pyramidale est utilisée (figure 7.5). Pour l'adaptation de domaine, le nombre de niveaux de la pyramide (i.e. la complexité spatiale) est fixé à $N_{\text{spatial}} = 4$. Ce niveau de complexité est choisi volontairement du fait qu'il n'est pas optimal pour la classification de la base cible en l'absence d'adaptation (cf. table 7.2). Le vecteur final résulte de la concaténation de $\sum_{n=1}^4 4^{n-1}$ descripteurs élémentaires. La complexité de quantification des descripteurs basés sur les segments de contour est fixée à $N_{\text{quantif.}} = 4$ ($N_l = N_\eta = 8$ et $N_\delta = 16$). La taille du dictionnaire est quant à elle fixée à $K = 150$. Cela conduit à des descripteurs de dimensions respectives 10880 et 12750.

Paramètres pour l'adaptation. Dans le but d'étudier le comportement et les limites de la procédure d'adaptation proposée, le seuil $\text{AUC}_{\text{min}}^*$ en entrée de l'algorithme 10 n'a, dans un premier temps, pas été fixé. La valeur de k a été choisie de telle sorte à éliminer 10% des caractéristiques à chaque itération. Les caractéristiques restantes sont ensuite utilisées pour l'apprentissage du classifieur dans le domaine source. La dimension finale du descripteur est fixée à $d = 100$. La réduction ultérieure de la dimension par $\phi'_d(\cdot)$ est réalisée à partir du jeu de caractéristiques courant, sans considérer les k caractéristiques éliminées.

Classifieurs. Les classifieurs utilisés, SVM et GentleBoost, ont été décrits à la section 7.1.2. De la même manière que dans la section 7.1.3 la réduction finale de la dimension (i.e. le calcul de $\phi'_d(\cdot)$) est obtenue par l'algorithme CMIM [Fleuret, 2004] dans le cas du SVM, et par un choix de $I = d$ classifieurs faibles (ne considérant qu'une seule caractéristique chacun pour la séparation des données) dans le cas de GentleBoost.

DASVM. L'algorithme DASVM, suggéré par [Bruzzone et Marconcini, 2010], a été choisi pour la comparaison. Bien que cet algorithme restreigne le choix du classifieur au SVM (contrairement à l'approche proposée qui est indépendante du classifieur), il est également adapté à la tâche considérée car il est capable de traiter des données de grande dimension. De plus, il est simple à implémenter et ne nécessite pas de mesure de similarité entre les distributions. La procédure de déroulement en trois phases, qui sont décrites dans l'annexe B. Dans notre implémentation, le paramètre $C_{\text{init.,S}}$ a été choisi par validation croisée d'ordre cinq. Les autres paramètres ont été fixés à $C_{\text{init.,T}} = 0,01$, $C_{\text{max,T}} = 0,5C_{\text{init.,S}}$ (comme préconisé par [Bruzzone et Marconcini, 2010]), $K = 10$, $\alpha = 0,1$, et $n_{\text{up}} = n_{\text{low}} = 100$.

Implémentation de l'IM L'implémentation de l'information mutuelle (7.11) est basée sur l'algorithme MIM⁷ également proposé par [Fleuret, 2004], qui permet un calcul rapide. Comme pour l'algorithme CMIM, les caractéristiques en entrée doivent être binaires. Une étape de binarisation préalable a été effectuée de manière similaire à l'équation (7.6), mais au lieu de considérer $\omega = \pm 1$, nous considérons ici $D = \pm 1$.

Optimisation de l'AUC La fonction de score optimale s^* (équation (7.14)) et le critère AUC^* associé ont été obtenus par l'utilisation de l'algorithme TreeRank⁸

7. Mutual Information Minimization.

8. L'implémentation R de TreeRank est disponible à l'adresse <http://treerank.sourceforge.net>

[Cléménçon et Vayatis, 2009]. Celui-ci consiste en une procédure récursive pour construire une fonction de score dont la courbe ROC est une approximation linéaire par morceaux de la courbe ROC optimale (ROC*). La fonction linéaire par morceaux est définie par une séquence de Z points $(\alpha_z, \beta_z)_{0 \leq z \leq Z}$ où $(\alpha_0, \beta_0) = (0, 0)$ et $(\alpha_Z, \beta_Z) = (1, 1)$. À chaque itération, une séparation optimale des données dans l'espace de représentation est recherchée pour ajouter un point entre chaque partie linéaire de la courbe ROC de manière à maximiser l'augmentation de l'AUC. Cela revient à une procédure de séparation récursive des données pour estimer AUC*. La séparation des données peut être effectuée par un quelconque classifieur supervisé. Dans les expérimentations, un classifieur SVM a été utilisé avec un noyau gaussien. Les paramètres du classifieur choisis sont les valeurs par défaut proposées par l'algorithme.

Validation du concept

Pour valider le principe de fonctionnement de la procédure d'adaptation de domaine proposée, un problème simple a tout d'abord été considéré. Seule la base source a été utilisée (figure 7.6.a). 30% des images ont été sélectionnées dans cette dernière pour constituer la base cible. Le biais entre les deux domaines a été introduit intentionnellement. Il est détaillé ci-après.

Biais source-cible. Plusieurs niveaux de biais ont été considérés entre les domaines source et cible. Pour cela, des masques binaires ont été appliqués sur les images de la cible, chacun d'entre eux ayant une aire masquée croissante. Les zones de masquage sont celles qui auraient été utiles pour la classification dans le domaine source. Ce choix particulier des zones masquées permet de garantir la nécessité d'une adaptation de domaine et d'évaluer l'apport de la méthode. Pour cela, une première estimation de la distribution spatiale des caractéristiques utiles au niveau le plus fin de la pyramide spatiale a été réalisée. Dans le cas de deux classes, l'utilité est mesurée par la capacité discriminante des caractéristiques, obtenue par l'algorithme CMIM [Fleuret, 2004]. Dans le cas multi-classes considéré ici (avec \mathcal{K} classes), cette sélection est réalisée \mathcal{K} fois avec la stratégie un contre tous. La distribution moyenne (issue des \mathcal{K} distributions obtenues) est alors utilisée pour en déduire les masques binaires. La figure 7.9 illustre le biais obtenu sur les images cibles.




FIGURE 7.9 – Masques binaires appliqués aux images pour biaiser le domaine cible; a. : 10%; b. : 20%; c. : 30%; d. : 40%;

Résultats. Pour un biais source-cible donné, une première étape de classement des caractéristiques par IM a été effectuée (ligne 1 de l'algorithme 10). Ce classement est illustré par la figure 7.10, qui représente la distribution des caractéristiques utiles pour l'adaptation sur la pyramide spatiale avec le masque de 10%. Elle révèle le lien entre l'IM et la structure sous-jacente des données. Les caractéristiques ont ensuite été éliminées progressivement à partir de ce classement (en commençant par les caractéristiques d'IM la plus élevée). L'apprentissage (après réduction ultérieure de la dimension) a été effectué à l'aide des caractéristiques restantes. Les résultats présentés ont été obtenus à partir d'une double validation croisée. Premièrement, une validation croisée d'ordre cinq a été effectuée pour le




FIGURE 7.10 – Validation du concept d'adaptation de domaine- Distribution moyenne (sur l'ensemble des classes) des meilleures caractéristiques (i.e. d'IM minimale) pour l'adaptation de domaine, répartie sur la pyramide de représentation. La distribution est obtenue avec le descripteur par segments de contour et un biais par masquage de 10% (cf. figure 7.9.a). a. : distribution des 50% meilleures ; b. : distribution des 70% meilleures ; c. : distribution des 90% meilleures ;

choix des images cibles (les images cibles ont à chaque fois été sélectionnées aléatoirement). Deuxièmement, pour un choix de la base source donné, une validation croisée d'ordre cinq a été effectuée sur cette base (la base cible est restée inchangée lors de cette deuxième validation croisée). L'annotation des images de la base cible a été nécessaire pour évaluer a posteriori les performances de l'adaptation, mais rappelons que l'annotation de la cible n'est pas utilisée lors de l'apprentissage. Les figures 7.11 et 7.12 reportent les performances de classification dans les domaines source et cible respectivement pour les classifieurs SVM et GentleBoost. L'évolution des performances en fonction du nombre de caractéristiques éliminées par l'IM est donnée pour plusieurs niveaux de biais, ainsi que l'évolution des AUC correspondantes.

Pour chaque niveau de biais non nul, la procédure d'adaptation de domaine conduit à une amélioration des performances sur le domaine cible par rapport à la performance initiale (sans adaptation). La table 7.4 reporte ces améliorations pour chaque combinaison de descripteur-classifieur. Ce comportement bénéfique est visible quelque soit la combinaison. Pour un biais nul, l'adaptation n'a en revanche pas l'effet escompté, ce qui était prévisible car dans ce cas aucune adaptation de domaine n'est nécessaire. La méthode proposée est plus efficace que le DASVM sur les bases de données considérées. Le DASVM non seulement ne parvient pas à améliorer les performances sur la source, mais il les dégrade même par rapport à une classification par SVM sans adaptation. Le succès de l'adaptation sur le domaine cible par notre approche est cependant au prix d'une légère baisse de performance sur le domaine source, car l'adaptation a également engendré l'élimination d'une partie des caractéristiques utiles pour la classification sur la source. Cela traduit le compromis attendu des performances entre la source et la cible. La décroissance de l'AUC dans chaque cas montre que plus les caractéristiques d'IM élevée sont éliminées, plus les domaines sont homogènes. Elle révèle l'efficacité de l'IM pour éliminer le biais entre les deux domaines.

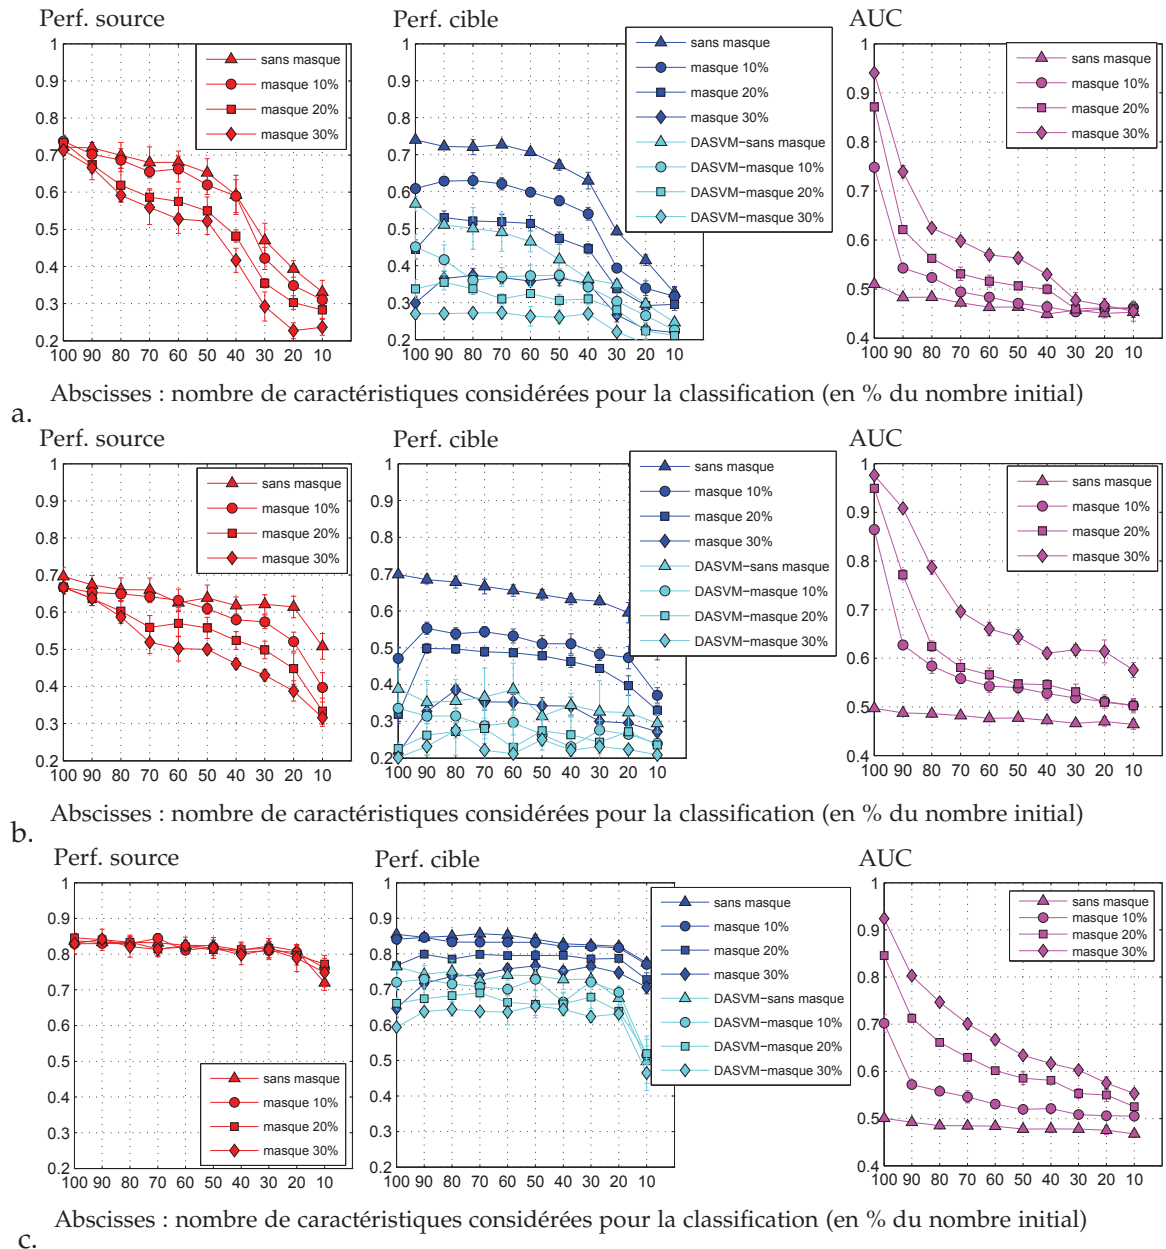


FIGURE 7.11 – Validation du concept d'adaptation de domaine - Résultats de classification par SVM sur les domaines source et cible en fonction du niveau d'adaptation, et évolution de l'AUC associée. a. : descripteur par segments de contour ; b. : descripteur par paires de segments ; c. : descripteur par vocabulaire visuel. Les performances avec le DASVM sont comparées sur la base cible.

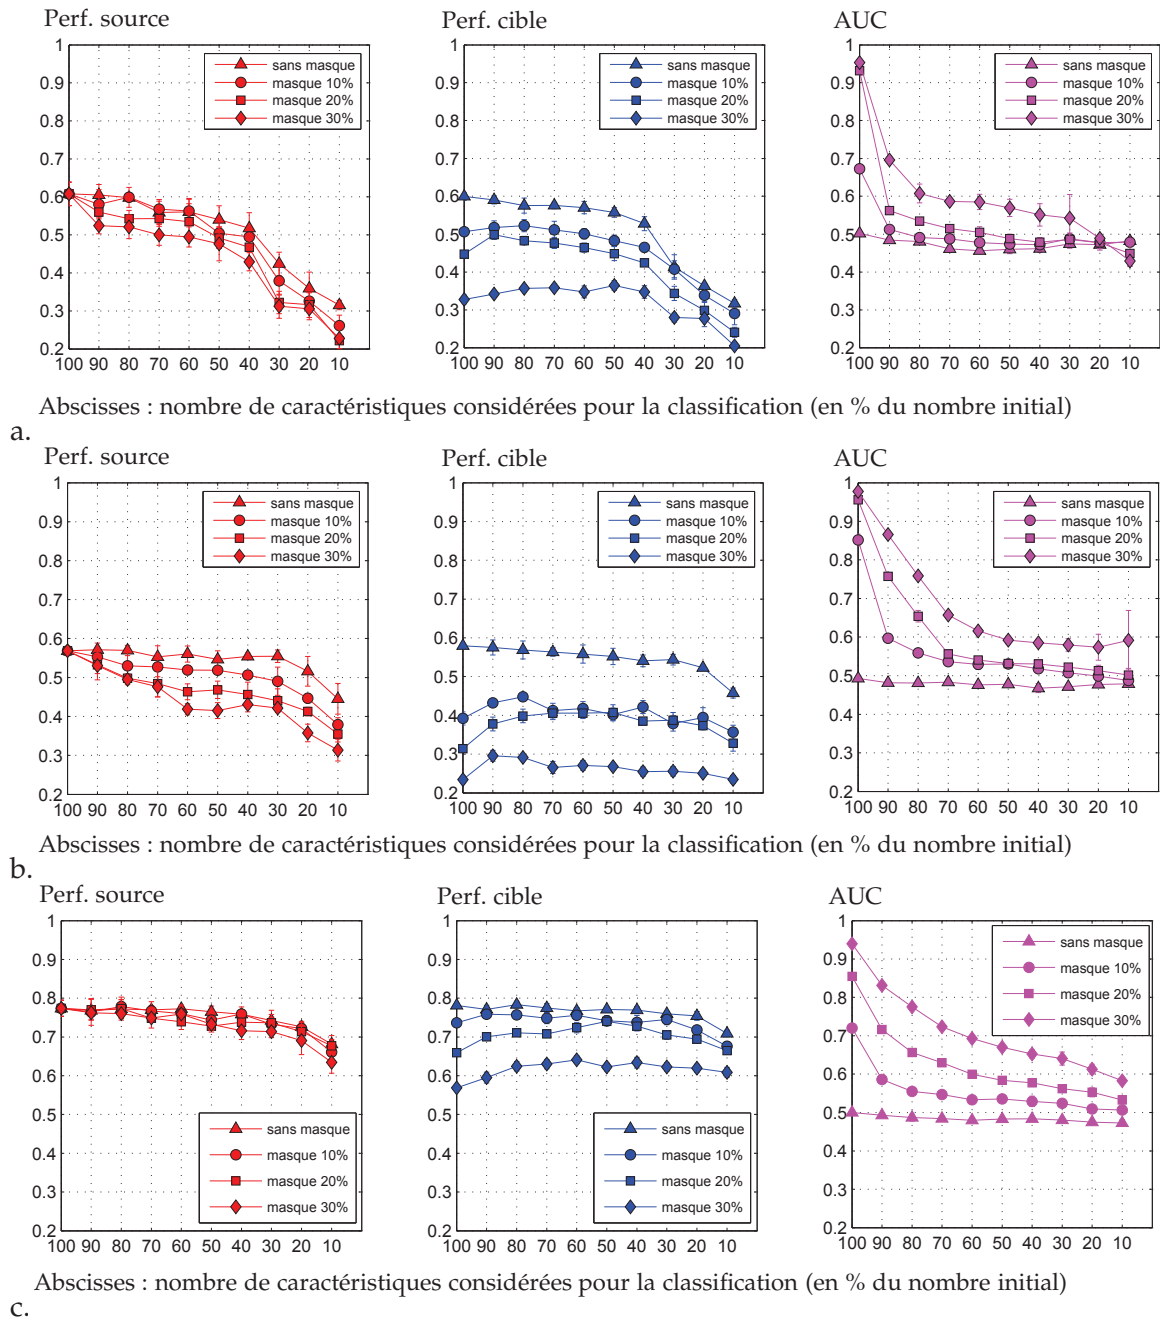


FIGURE 7.12 – Validation du concept d'adaptation de domaine - Résultats de classification par GentleBoost sur les domaines source et cible en fonction du niveau d'adaptation, et évolution de l'AUC associée. a. : descripteur par segments de contour ; b. : descripteur par paires de segments ; c. : descripteur par vocabulaire visuel. Les performances avec le DASVM sont comparées sur la base cible.

	SVM, seg. de contour		SVM, paires de seg.		SVM, sac de mots		GentleBoost, seg. de contour		GentleBoost, paires de seg.		GentleBoost, sac de mots	
	source	cible	source	cible	source	cible	source	cible	source	cible	source	cible
a												
avant												
perf.	0,74	0,61	0,67	0,47	0,83	0,84	0,61	0,51	0,61	0,51	0,77	0,74
éc. type	0,02	0,01	0,02	0,03	0,03	0,01	0,03	0,01	0,03	0,01	0,02	0,01
après												
perf.	0,67	0,63	0,65	0,55	0,83	0,85	0,60	0,52	0,60	0,52	0,76	0,76
éc. type	0,03	0,02	0,01	0,02	0,01	0,01	0,03	0,01	0,03	0,02	0,03	0,01
b												
avant												
perf.	0,73	0,44	0,67	0,32	0,85	0,77	0,61	0,45	0,61	0,45	0,77	0,66
éc. type	0,02	0,02	0,01	0,02	0,01	0,01	0,03	0,01	0,03	0,01	0,02	0,01
après												
perf.	0,62	0,53	0,64	0,50	0,84	0,80	0,56	0,50	0,56	0,49	0,73	0,74
éc. type	0,04	0,02	0,02	0,01	0,03	0,01	0,04	0,01	0,04	0,01	0,01	0,02
c												
avant												
perf.	0,71	0,30	0,67	0,21	0,83	0,65	0,61	0,33	0,61	0,33	0,77	0,66
éc. type	0,02	0,02	0,01	0,02	0,01	0,01	0,03	0,01	0,03	0,01	0,02	0,01
après												
perf.	0,59	0,37	0,59	0,39	0,82	0,77	0,48	0,36	0,50	0,36	0,76	0,64
éc. type	0,02	0,02	0,02	0,01	0,03	0,01	0,04	0,01	0,03	0,01	0,01	0,01

TABLE 7.4 – Validation du concept d'adaptation de domaine - Résumé des performances de classification avant et après adaptation pour les différents descripteurs et classifieurs considérés ($N_{quantif.} = 3$ et $N_{spatial} = 4$); a. : masque 10%; b. : masque 20%; c. : masque 30%. Les performances après adaptation reportées correspondent aux performances maximales sur la cible.

Adaptation de domaine avec biais inconnu

Une deuxième série d'expérimentations a été réalisée, dans laquelle le biais est cette fois inconnu. Le domaine source est formé par la base de données de la figure 7.6.a tandis que le domaine cible par celle de la figure 7.6.b. Le protocole expérimental est le même que pour l'évaluation précédente. La figure 7.13 illustre la distribution spatiale des caractéristiques sélectionnées par l'IM pour l'adaptation. Celles-ci se concentrent en moyenne sur l'objet (la zone centrale de l'image). Il est à noter que l'élimination des caractéristiques autour de l'objet (le fond) ne permet pas d'expliquer à elle seule la suppression du biais entre les deux domaines. En effet, l'étape de réduction ultérieure de la dimension (par CMIM ou boosting) tend elle-même à sélectionner les caractéristiques sur l'objet (comme le montre la figure 7.9 dans le cas du CMIM). Or, en l'absence d'adaptation, cette sélection seule ne conduit pas à des performances aussi élevées sur le domaine cible (voir la table 7.5).

Les performances et l'évolution de l'AUC en fonction du nombre de caractéristiques éli-

	SVM, seg. de contour		SVM, paires de seg.		SVM, sac de mots		GentleBoost, seg. de contour		GentleBoost, paires de seg.		GentleBoost, sac de mots	
	source	cible	source	cible	source	cible	source	cible	source	cible	source	cible
avant												
perf.	0,77	0,50	0,73	0,50	0,87	0,57	0,67	0,42	0,64	0,41	0,82	0,48
éc. type	0,03	0,01	0,03	0,01	0,01	0,01	0,02	0,01	0	0,01	0	0
après												
perf.	0,74	0,55	0,70	0,51	0,85	0,59	0,64	0,43	0,62	0,43	0,79	0,51
éc. type	0,02	0,01	0,01	0,01	0,01	0,01	0,03	0,01	0,02	0,01	0,01	0

TABLE 7.5 – Cas réel - Résumé des performances de classification avant et après adaptation pour les différents descripteurs et classifieurs considérés ($N_{quantif.} = 3$ et $N_{spatial} = 4$). Les performances après adaptation reportées correspondent aux performances maximales sur la cible.

minées par l'IM sont illustrées par la figure 7.14. La table 7.5 récapitule les gains de performance obtenus pour l'ensemble des descripteurs et classifieurs utilisés. Ces performances montrent la pertinence de l'approche proposée face à un cas d'adaptation complexe tel que celui-ci. La sélection des caractéristiques par la méthode proposée se révèle ici encore bénéfique pour l'adaptation, bien que l'apport soit plus ou moins important suivant la nature




FIGURE 7.13 – Cas réel (biais inconnu) - Distribution moyenne (sur l'ensemble des classes) des meilleures caractéristiques (i.e. d'IM minimale) pour l'adaptation de domaine, répartie sur la pyramide de représentation. La distribution est obtenue avec le descripteur par segments de contour. a : distribution des 10% meilleures ; b : distribution des 30% meilleures ; c : distribution des 50% meilleures ;

du descripteur et du classifieur. Le DASVM ne permet en revanche pas d'adapter le SVM sur la cible quel que soit le descripteur utilisé.

Critères d'arrêt de l'adaptation

Les résultats précédents ont montré l'efficacité de la procédure d'adaptation proposée pour un choix convenable du nombre de caractéristiques éliminées. Ce degré d'adaptation, contrôlé par la mesure de similarité AUC, est en pratique fixé via le seuil AUC_{\min}^* . Cependant, un seuil trop élevé n'aurait aucun effet, et les figures 7.12 et 7.13 montrent qu'un seuil trop bas conduirait à une adaptation excessive entraînant une chute générale des performances. Bien que le choix du paramètre AUC_{\min}^* dépende du problème traité et des impératifs propres à l'utilisateur, la détermination d'un intervalle de valeurs pertinentes est susceptible de guider le choix de l'utilisateur. Cet intervalle peut être obtenu en considérant l'évolution de l'écart de performance source-cible en fonction de l'AUC. Cet écart est visible à la figure 7.15. Celui-ci est décroissant au début de l'adaptation (i.e. pour des AUC grandes), puis devient croissant lorsque l'AUC diminue de manière trop importante (i.e. l'effet de l'adaptation devient négatif). L'écart de performance minimal permet de déterminer une valeur de référence pour AUC_{\min}^* . Bien que la variance des courbes soit trop importante pour déterminer avec robustesse le minimum global, la tendance des courbes offre une aide à la décision : une valeur trop petite ou trop grande de l'AUC n'est pas recommandée. Ces courbes permettent de conjecturer une valeur de AUC_{\min}^* pour une adaptation de domaine bénéfique.

Notons toutefois que cette conjecture n'est possible que par l'annotation de données dans la base cible (pour le calcul de la performance cible). Cependant, seule une faible quantité de données annotées est susceptible de suffire pour cette conjecture (au regard de la variance raisonnable des courbes). Cette annotation partielle requiert un effort beaucoup moins important que celui déployé dans la base source.

7.3 DISCUSSIONS

La classification d'aspect mise en œuvre dans ce chapitre se révèle efficace pour l'application considérée, en atteignant un taux de performance supérieur à 85% sur les données de test (avec huit classes). Les résultats obtenus pour l'ensemble des descripteurs et des classifieurs considérés ont montré que la généralisation du classifieur était délicate sur la base source, et bien plus encore sur la base cible dont la distribution (inconnue) sous-jacente

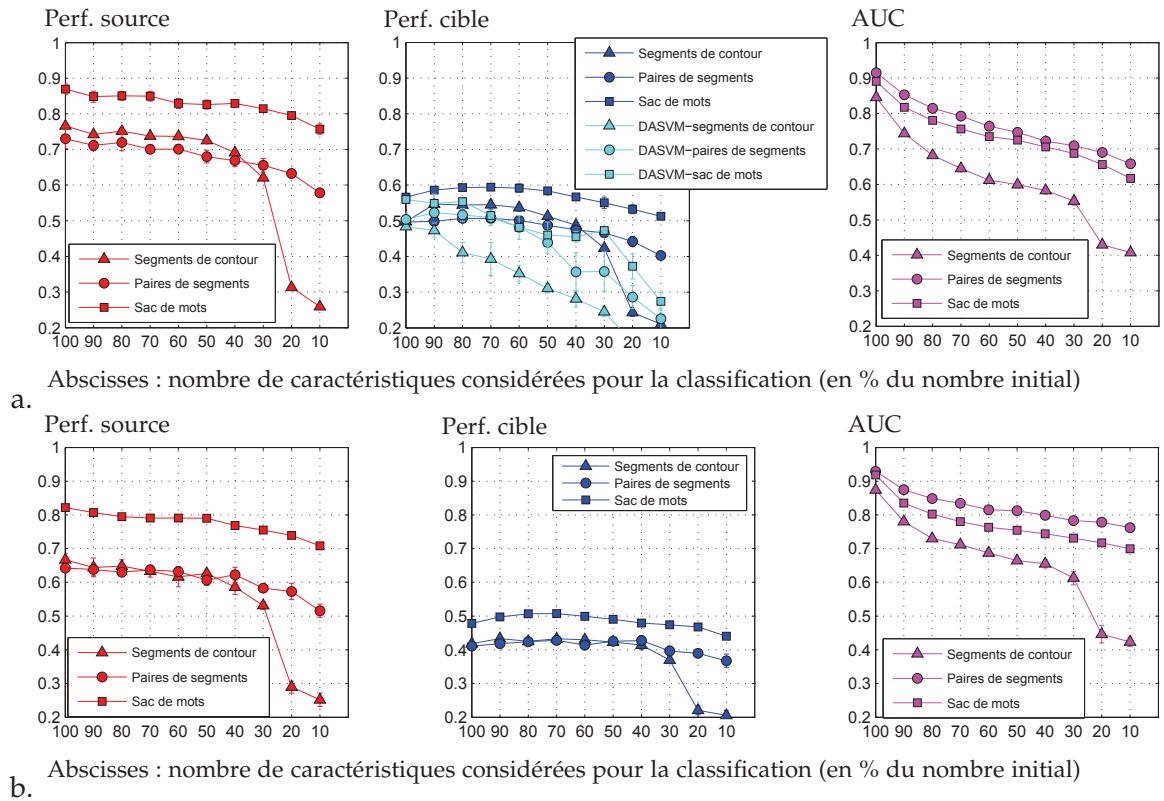


FIGURE 7.14 – Cas réel (biais inconnu) - Résultats de classification sur les domaines source et cible en fonction du niveau d'adaptation, et évolution de l'AUC associée. a : Classification par SVM ; b : Classification par GentleBoost ; Les performances avec le DASVM sont comparées sur la base cible.

diffère. Le choix de la complexité du descripteur, ainsi que la nature du couple descripteur-classifieur, offre une première stratégie d'amélioration de la généralisation. Comme le soutiennent [Ben-David et al., 2007], la nature de la représentation joue elle-même un rôle important pour l'adaptation de domaine. D'autres représentations pourraient être envisagées dans cette optimisation de la généralisation.

Cependant, les évaluations présentées à la section 7.2.6 ont permis de valider le bénéfice de la stratégie d'adaptation par sélection de caractéristiques. Elles ont également montré que cette stratégie est pertinente lorsque le biais entre les deux domaines est inconnu, en particulier lorsque l'hypothèse de corrélation entre les deux domaines n'est pas vérifiée (ce qui a conduit à l'inefficacité du DASVM). Elle s'est de plus révélée compatible avec plusieurs descripteurs et classifieurs, et autorise un niveau de complexité des descripteurs élevé (i.e. une complexité optimale pour la classification dans le domaine source) tout en augmentant les performances dans le domaine cible.

Ici, le descripteur par sac de mots conduit à des performances supérieures sur la base cible par rapport aux autres descripteurs, ce qui révèle sa capacité naturelle à s'adapter. La nature du classifieur se révèle également importante, le SVM est ici plus performant que GentleBoost pour les choix adoptés des noyaux et des classifieurs faibles. La méthode d'adaptation proposée laisse cependant entrevoir des améliorations possibles. Une première limitation concerne le choix optimal du seuil AUC_{\min}^* . Celui-ci ne peut être guidé que par l'annotation d'une partie de la base cible. Cela va à l'encontre du reste de la procédure et de l'ambition d'adapter le classifieur dans le cas extrême où aucune donnée cible n'est annotée. Néanmoins, la nécessité d'annoter en partie la base cible apparaît dans la plupart des travaux en adaptation de domaine pour la classification d'images [Saenko et al., 2010; Kulis et al., 2011].

Une deuxième limitation est liée au choix d'une représentation spatiale pyramidale qui, bien que permettant une description plus efficace, n'est pas invariante par transla-

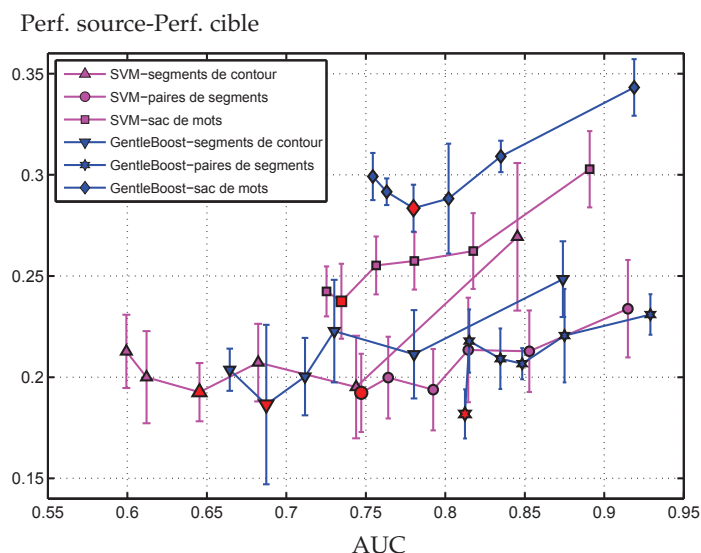


FIGURE 7.15 – Cas réel (biais inconnu) - Écart de performance source-cible en fonction de l'AUC (les valeurs au delà de 50% de caractéristiques éliminées ne sont pas considérées). Les marqueurs rouges indiquent le minimum global de chaque courbe correspondant au choix préférentiel de AUC_{\min}^* .

tions des objets sur l'image ni par leur rotation dans le plan. Une manière d'augmenter sa robustesse serait de supprimer l'information géométrique de la description, comme dans [Saenko et al., 2010], mais les performances de classification sur le domaine source s'en trouveraient affectées. Le choix d'une grille spatiale particulière serait également susceptible de pallier de telles variations intra-classe lorsque celles-ci sont connues (par exemple, une grille polaire rendrait le descripteur invariant par rotation dans le plan).

Une troisième amélioration possible de la procédure réside dans la sélection des caractéristiques pour l'adaptation. Dans ce chapitre, seule l'IM a été considérée pour comparer les structures sous-jacentes des données. Cependant, le score de chaque caractéristique par cette mesure est obtenu indépendamment des autres. Or, si deux caractéristiques considérées une par une ne permettent pas de discriminer les deux domaines, la réunion des deux est en revanche susceptible de le permettre. L'IM peut alors conserver des caractéristiques qu'elle juge utiles pour l'adaptation sans observer que leur réunion peut s'avérer néfaste. Un classement de chaque caractéristique prenant en compte l'influence des autres est susceptible de conduire à une adaptation de domaine plus efficace. Un tel classement peut par exemple être obtenu par la performance de discrimination source-cible (par apprentissage d'un classifieur) à partir de l'ensemble des caractéristiques, puis en retirant l'une d'entre elles pour évaluer son importance. Cette stratégie, qui est à l'opposé de l'indépendance des caractéristiques par l'IM, est hautement combinatoire. Une recherche de stratégies de classement de caractéristiques offrant un compromis entre indépendance et complexité est une piste à explorer.

Enfin, la procédure d'estimation de la pose réalisée dans ce chapitre doit par la suite être intégrée au processus de reconnaissance active et évaluée en combinaison avec les stratégies de planification proposées dans les chapitres précédents. La classification d'aspect proposée pourrait en particulier être suivie d'une étape d'estimation plus fine de la pose. Une solution possible serait d'augmenter le nombre de classes (c'est le cas notamment de [Ozuysal et al., 2009]), ou bien d'utiliser le résultat de la classification pour initialiser la position d'un modèle polyédrique à apparier sur l'objet. Cette intégration reste en dehors du cadre de cette thèse mais constitue la prochaine étape vers une autonomie totale de l'agent.

CONCLUSION DU CHAPITRE

Ce chapitre s'est concentré sur l'estimation des CPDV réellement atteintes par l'agent en chaque observation dans son processus de reconnaissance active. Une estimation par un classifieur d'aspect a été adoptée, ce dernier étant issu d'un apprentissage supervisé. Le problème de la généralisation du classifieur, qui est inhérent en apprentissage statistique, a été abordé. Dans ce cadre, deux contributions ont été apportées. Dans la première, une étude de la nature et de la complexité du classifieur a montré que ces deux notions influencent sensiblement la capacité de généralisation et permettent de guider le choix d'une représentation pour l'application considérée. Dans la deuxième contribution, la généralisation à une base de données cible a été considérée. Une nouvelle approche d'adaptation de domaine a été proposée et évaluée lorsque les données à classifier sont issues d'une distribution différente de celle de la base d'apprentissage (source). Cette approche, basée sur une sélection de caractéristiques du descripteur, est compatible avec le vaste panel de descripteurs et de classifieurs pour la reconnaissance d'objets. Par une mesure de la structure sous-jacente des données associée à une mesure de similarité entre deux distributions, cette approche s'est révélée efficace pour l'application considérée, et surpasse en particulier la récente technique de DASVM. Le classifieur d'aspect obtenu, en étant davantage généralisé, offre, en plus des stratégies de planification, l'autonomie nécessaire à l'agent visuel pour la reconnaissance active.

RÉSUMÉ

<i>Positionnement</i>	<ul style="list-style-type: none"> · Estimation automatique de la pose des objets à chaque observation pour assurer la cohérence du placement de l'agent avec les CPDV planifiées. · L'application considérée est la classification d'aspect des véhicules. Deux bases de données (source et cible) sont considérées. · Le classifieur est appris sur la base source. Sa capacité de généralisation est particulièrement prise en compte.
<i>Contributions</i>	<ul style="list-style-type: none"> · Analyse de plusieurs descripteurs et classifieurs supervisés ainsi que de la complexité de description pour optimiser la généralisation (sur la source et sur la cible). Le choix d'une représentation pour l'application étudiée est guidé par cette analyse. · Introduction d'une nouvelle stratégie d'adaptation de domaine par sélection de caractéristiques, permettant d'améliorer la généralisation sur la base cible sans réitérer l'apprentissage du classifieur. Les performances de classification sont supérieures à celles de la récente technique DASVM.
<i>Limitations</i>	<ul style="list-style-type: none"> · Le paramètre impliqué dans la procédure d'adaptation nécessite l'annotation d'une partie des données cibles pour être choisi convenablement. · La sélection des caractéristique est basée sur une hypothèse d'indépendance de celles-ci. La suppression de cette hypothèse est susceptible d'améliorer encore les performances d'adaptation. · L'intégration de la procédure d'estimation de la pose dans le processus de reconnaissance active et son évaluation constituent la prochaine étape.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Le travail présenté dans cette thèse s'est intéressé à la reconnaissance active d'objets 3D par un agent visuel autonome. La reconnaissance à partir d'une information visuelle 2D (l'image) est un problème intrinsèquement mal posé dû à la perte d'information liée à la projection. Pour pallier cette difficulté, nous avons considéré la reconnaissance à partir d'une séquence d'observations. En choisissant activement les modalités d'acquisition dans un processus bouclé entre observation et décision, une reconnaissance non ambiguë a été recherchée. Deux points ont en particulier été abordés : *apprendre à planifier sous contrainte*, et *interpréter au mieux les observations au cours de la reconnaissance*. Nous nous sommes en particulier intéressés au cas où les modalités d'acquisition sont les CPDV. Dans ce cas, la politique de planification impliquée dans le processus de reconnaissance active prescrit à l'agent les déplacements à effectuer dans la scène relativement à l'objet pour lever l'ambiguïté de reconnaissance. Les contributions proposées ont été appliquées au problème de reconnaissance active de véhicules. Du fait de leur similarités intrinsèques importantes, ces derniers sont particulièrement appropriés pour évaluer la performance des stratégies proposées.

Un ensemble de travaux, qui constitue aujourd'hui l'état de l'art en reconnaissance active, a été rassemblé en introduction. Ils constituent le point de départ de cette thèse. Comme nous l'avons vu dans la première partie, la reconnaissance active par ordinateur fait appel à un ensemble de domaines connexes, parmi lesquels l'apprentissage statistique, le traitement d'images, la fusion de données, ou encore la commande. De nombreux travaux ont été effectués, l'apport de chacun d'entre eux étant sur un domaine particulier de la reconnaissance active. Ils ont été détaillés au cours des chapitres abordant les domaines correspondants.

La classification automatique d'image impliquée en reconnaissance active a fait l'objet de nombreux travaux que nous avons détaillé au chapitre 1. En particulier, les principales approches de description et d'apprentissage statistique, regroupées en terme de modélisation générative et modélisation discriminative des objets, ont été abordés. Cette revue de l'état de l'art nous a permis d'être guidés dans le choix d'une représentation pour la reconnaissance active.

La fusion des inférences issues de chaque observation en un classifieur unique a fait l'objet du chapitre 2. Un schéma d'accumulation bayésien a été défini. Le cadre probabiliste adopté permet de propager les différentes sources d'information (a priori, modèles, mesures) dans le processus d'accumulation et d'inférence. Cette propagation prend en compte l'incertitude en la prise de décision, qui est inhérente à la reconnaissance active. L'originalité du schéma proposé tient à son aspect spécifique à la reconnaissance active : un terme de sélection des prochaines modalités d'acquisition, $P(v_{t+1} | \mathbf{X}_t, \mathbf{V}_t, \omega)$, intervient explicitement, modélisant la politique de planification. Mais ce schéma se veut également générique : celui-ci fait intervenir un ensemble de paramètres θ constituant les modèles d'objets. Il permet d'envisager de nombreuses stratégies de modélisation et de planification. Trois critères, $Perf_{\max}$, T_{moy} et $Aire_T$, ont également été définis pour évaluer la performance des stratégies de planification.

La modélisation des véhicules, qui sont les objets considérés dans cette thèse pour

l'application de la reconnaissance active, a ensuite été abordée au chapitre 3. Une modélisation de vraisemblance a été adoptée, permettant un apprentissage indépendant pour chaque objet et offrant une compatibilité naturelle avec le cadre probabiliste. Les CPDV réellement atteintes par l'agent (v_0) en chaque observation ont dans un premier temps été supposées correspondre à celle prescrites par la politique de planification (v_{t+1}). Mais cette connaissance peut cependant être incertaine, et une modélisation de cette incertitude (i.e. de la probabilité $P(v_0 | v_{t+1})$) a également été formulée au chapitre 3 (l'estimation des CPDV fait l'objet du chapitre 7).

Les contributions apportées dans cette thèse se sont articulées autour d'un aspect commun qui est celui d'une mise en œuvre réaliste de la reconnaissance active. Dans la deuxième partie du document, ce souci de réalisme s'est attaché en particulier à *apprendre à planifier sous contrainte*.

Les modèles d'objets $P(x | \omega)$ appris à l'aide de données réelles non segmentées, ne sont pas parfaits. Ces imperfections, indissociables d'un cadre applicatif réaliste, constituent une rupture forte avec l'état de l'art. Une estimation robuste des CPDV avec de tels modèles n'est plus garantie, et les similarités intrinsèques n'expliquent plus à elles seules les écueils de la reconnaissance. La prise en compte de ces défauts de modélisation dans la planification des CPDV a été pour la première fois considérée dans cette thèse, au chapitre 4. Nous avons montré que la planification basée sur l'entropie ne permettait pas de capturer ces défauts de modélisation. Un nouveau critère a pour cela été défini, le *critère adaptatif* (et sa variante, le critère *max-adaptatif*). En basant la sélection des CPDV sur le résultat espéré du classifieur à partir d'un apprentissage, le nouveau critère défini a permis d'adapter la planification à la modélisation disponible. Après chaque observation, l'hypothèse courante sur la classe de l'objet (ω_t) intervient dans la sélection des CPDV de manière à éviter, en plus des similarités intrinsèques, les défauts du modèle correspondant. Cette stratégie de sélection intervenant dans la planification s'est révélée très bénéfique pour l'application considérée. Elle augmente significativement les performances de reconnaissance active par rapport à l'état de l'art.

Au chapitre 5 nous avons défini une nouvelle approche pour apprendre à planifier avec un budget d'observations limité, deuxième rupture importante avec l'état de l'art. Le critère adaptatif précédent a été intégré dans une procédure d'apprentissage par renforcement combinée avec les processus gaussiens. L'apprentissage par renforcement, en particulier les méthodes *Q-learning* et programmation dynamique que nous avons abordé, offrent à elles seules un cadre de planification non myope (l'horizon de planification $H > 0$). Dans ce cas, la sélection des CPDV est basée sur les conséquences à long terme pour la reconnaissance. Les processus gaussiens permettent quant à eux un échantillonnage actif des observations d'apprentissage de manière à diminuer leur nombre sans sacrifier les performances. Cette combinaison novatrice s'est avérée efficace. Pour une planification myope, le budget d'observation est réduit d'un facteur supérieur à 10, et une planification non myope améliore sensiblement les performances de reconnaissance active.

La troisième partie du document et les contributions qui y ont été proposées s'attachent à *interpréter au mieux les observations au cours de la reconnaissance*. Les techniques d'apprentissage supervisé, qui sont désormais omniprésentes en classification d'images et qui offrent à l'heure actuelle les meilleures performances dans de nombreux contextes, ont pour cela été mises à profit.

Dans le chapitre 6, nous nous sommes intéressés à la possibilité d'une interprétation intermédiaire dès la première observation et tout au long du processus d'acquisition séquentiel impliqué en reconnaissance active. Les travaux précédents ne considèrent l'interprétation qu'après un nombre fixe d'observations ou bien lorsqu'un critère d'arrêt est atteint, sans considérer une échelle d'interprétation plus grossière comme alternative au rejet. Nous avons en particulier considéré le cas d'un nombre de classes croissant dans la base

de données et avons montré à travers les critères de planification que l'augmentation de ce nombre augmentait également la difficulté à inférer la classe de manière non ambiguë. Pour cela, la stratégie que nous avons proposée a consisté à définir une hiérarchie d'interprétation par le biais d'un GAO, chaque nœud contenant un cadre de discernement de taille décroissante avec le niveau dans le graphe. Un filtrage de classes à partir du résultat de l'inférence permet un parcours autonome dans le graphe, fournissant une interprétation provisoire avec un niveau de confiance acceptable. Le seuil de filtrage de classe P_{\min} est un paramètre choisi par l'utilisateur. Cependant, un mauvais réglage peut conduire à l'élimination erronée de la classe de l'objet. Pour cela, nous avons réalisé une étude de l'influence de P_{\min} sur les performances de reconnaissance et établi, à travers les expérimentations, une aide pour un choix convenable. La réduction progressive du cadre de discernement a conduit certaines CPDV jusqu'alors peu informatives à devenir bénéfiques pour la reconnaissance. Dans ce but, nous avons construit une hiérarchie de planification, appelée planification AME, capable de capturer cette émergence au cours de la reconnaissance. Ce couplage entre classification hiérarchique et planification AME a montré, à travers la reconnaissance de véhicules, qu'un compromis entre confiance et précision de l'interprétation était désormais envisageable en reconnaissance active.

L'exploitation des observations pendant la reconnaissance est également nécessaire pour estimer les CPDV (i.e. la pose de l'objet relativement à l'agent). La contrainte de modèles imparfaits considérée dans cette thèse ne permet pas d'envisager, comme dans les travaux précédents, une estimation jointe classe-pose robuste. Pour cela, nous avons développé au chapitre 7 une estimation indépendante par classification supervisée. Un classifieur d'aspect a en particulier été adopté, avec pour objectif de le substituer au modèle d'incertitude considéré jusqu'à présent. Deux bases de données, source et cible, ont été utilisées pour les expérimentations, la base cible (non annotée) présentant un biais inconnu par rapport à la base source. La généralisation du classifieur (appris sur la base source annotée) sur les deux bases a été recherchée. Nous avons tout d'abord analysé plusieurs descripteurs d'images et classifieurs, ainsi qu'une complexité de description variable (via $N_{\text{quantif.}}$ et N_{spatial}) dans le but d'optimiser la généralisation. Pour améliorer davantage celle-ci sur la base cible, une nouvelle approche d'adaptation de domaine du classifieur a été proposée. Le souci à la fois d'une compatibilité avec des descripteurs de grande dimension et d'une généralité face à des représentations et des classifieurs variés a été pris en compte. En basant l'adaptation sur la recherche d'un sous-espace de représentation commun aux domaines source et cible, notre approche s'est révélée prometteuse, en augmentant sensiblement les performances de classification sur la cible sans sacrifier celles sur la source. Le degré d'adaptation est contrôlé par le paramètre AUC_{\min}^* issu d'une mesure de similarité non paramétrique entre deux distributions. Pour choisir convenablement ce critère, nous avons proposé une démarche applicable dès qu'une partie des données cible est annotée.

PERSPECTIVES

Cette thèse ouvre un ensemble de perspectives dans la continuité directe du travail réalisé. La plupart d'entre elles ont été énoncées au sein de chaque chapitre. Néanmoins, au delà de ces perspectives à court terme, nous pouvons relever un ensemble de perspectives à plus long terme constituant autant d'axes de recherche potentiels.

- La première d'entre elles concerne la combinaison des différents éléments de la chaîne de traitement (dont ceux abordés dans cette thèse) et de leurs avantages pour la reconnaissance active. D'une part, les stratégies d'apprentissage de la politique de planification développées aux chapitres 4 et 5 pourraient être couplées à la planification AME (chapitre 6) et à l'estimation en ligne des CPDV (chapitre 7). D'autre part, la chaîne globale de reconnaissance active pourrait être complétée par les étapes de détection et le suivi des objets.

- Une deuxième perspective possible serait la prise en compte d'un plus grand nombre de modalités d'acquisition dans la planification. Seule la sélection des CPDV a été considérée, mais le cadre établi au chapitre 2 offre l'avantage de pouvoir s'appliquer à tous les paramètres dont le contrôle actif est possible et susceptible d'enrichir l'information collectée. En particulier, pour les véhicules, la recherche de zones locales discriminantes au sein de chaque observation (en modifiant la focale du capteur, ou simplement par sélection dans l'image) pourrait être guidée activement.
- La conception d'une modélisation plus juste des données serait susceptible d'améliorer les performances de reconnaissance. En particulier, une approche par modèles discriminatifs (abordés au chapitre 1), comme les modèles de constellations, qui offrent des performances élevées dans de nombreux contextes, pourrait s'avérer efficace également en reconnaissance active. L'apprentissage de tels modèles pour des objets 3D à l'aide de données réelles (donc bruitées et/ou partiellement occultées) est un travail à part entière.
- Une dernière perspective que nous pouvons citer consiste à exploiter la possibilité d'une acquisition à cadence élevée (vidéo) pour la reconnaissance. Ainsi, plutôt que de planifier la prochaine observation, le formalisme proposé pourrait être étendu afin de planifier une trajectoire (elle-même constituée d'un ensemble d'observations). De cette manière, les informations de la scène pourraient être extraites et exploitées tout au long des déplacements de l'agent.

ANNEXES

CONSTRUCTION DE LA BASE DE DONNÉES DE VÉHICULES

A

Dans cette annexe, les principales étapes de la construction de la base de données de véhicules pour la reconnaissance active (présentée au chapitre 3) sont décrites. Ces étapes comprennent la calibration de la caméra (utilisée pour l'annotation), l'acquisition des observations et l'annotation des images acquises.

A.1 DESCRIPTION DU DISPOSITIF D'ACQUISITION




FIGURE A.1 – Matériel utilisé pour la construction de la base de données.

Le matériel utilisé pour l'acquisition des images constituant la base de données est représenté à la figure A.1. Un plateau tournant (sur lequel sont posés les objets) permet l'acquisition quelque soit l'azimut relative objet-caméra. Les quatre petites mires disposées sur le plateau sont utilisées pour l'annotation de la pose des objets (cf. section A.3).

A.2 CALIBRATION DE LA CAMÉRA

La calibration de la caméra consiste à estimer un ensemble de paramètres intrinsèques et extrinsèques à la caméra de manière à déterminer la relation entre un point de la scène et sa position sur l'image. La calibration fait appel à la géométrie projective. Le modèle généralement utilisé est celui du sténopé. Il est basé sur une hypothèse de linéarité entre la scène et la formation de son image dans un espace projectif. Les différents repères et

paramètres impliqués dans la procédure de calibration sont résumés par la figure A.2. Parmi eux, nous pouvons noter :

- Le repère monde (X_w, Y_w, Z_w) dans lequel les coordonnées d'un point O sont exprimées.
- Le repère caméra (X_c, Y_c, Z_c) . Par convention, Z_c est orienté selon l'axe optique.
- Le repère image (U, V) .




FIGURE A.2 – Illustration du modèle de caméra utilisé pour la calibration.

Les coordonnées du point O dans le repère image sont notées (u_O, v_O) . La connaissance de celles-ci requiert le calcul de deux matrices de passage :

- La première d'entre elles est la matrice de passage du repère monde vers le repère caméra, notée H . En utilisant la notation matricielle des coordonnées homogènes, elle est définie par :

$$H = \left(\begin{array}{c|c} \mathbf{R}_{3 \times 3} & \mathbf{T}_{3 \times 1} \\ \hline 0 & 1 \end{array} \right) \quad (\text{A.1})$$

où la matrice $\mathbf{R}_{3 \times 3}$ est une matrice de rotation et le vecteur $\mathbf{T}_{3 \times 1}$ est un vecteur de translation. $\mathbf{R}_{3 \times 3}$ et $\mathbf{T}_{3 \times 1}$ sont appelés les *paramètres extrinsèques*.

- La deuxième matrice de passage permet d'exprimer les coordonnées du point O depuis le repère caméra vers le repère image. Elle est conventionnellement notée K . En utilisant également les coordonnées homogènes, la matrice K est définie par :

$$K = \begin{pmatrix} f_x & 0 & c_u \\ 0 & f_y & c_v \\ 0 & 0 & 1 \end{pmatrix} = \begin{pmatrix} k_u & s_{uv} & c_u \\ 0 & k_v & c_v \\ 0 & 0 & 1 \end{pmatrix} \times \begin{pmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \quad (\text{A.2})$$

Le paramètre f est la distance focale, k_u et k_v sont les facteurs d'agrandissement de l'image, c_u et c_v sont les coordonnées de la projection du centre optique de la caméra sur l'image, et le paramètre s_{uv} traduit la non orthogonalité entre U et V (i.e. $\eta \neq \frac{\pi}{2}$). La matrice K regroupe les *paramètres intrinsèques* de la caméra.

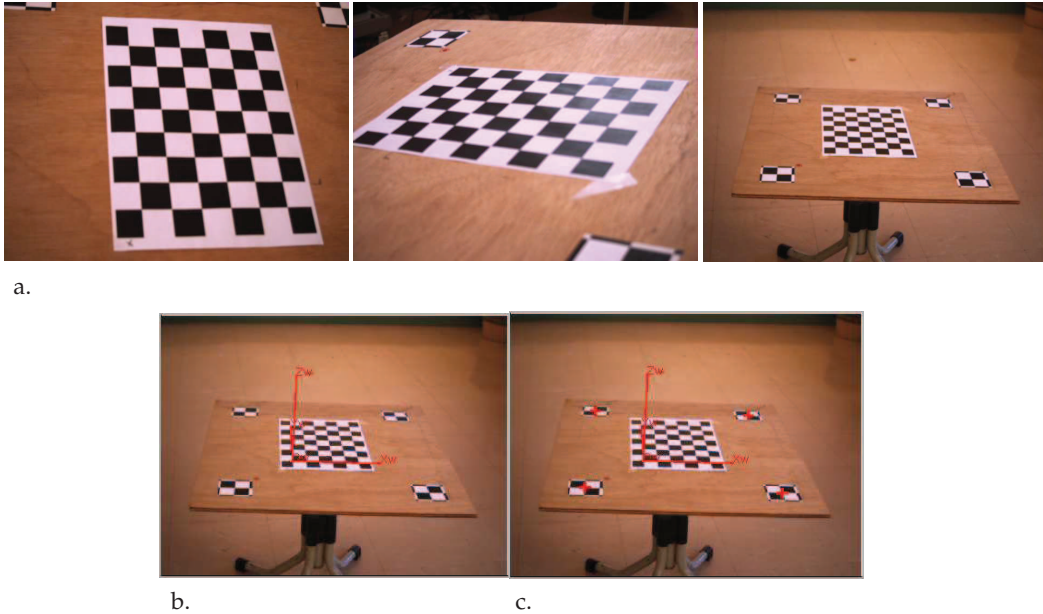


FIGURE A.3 – Calibration de la caméra. La dernière mire est placée sur le plateau de sorte à calibrer le système dans un repère monde lié au plateau. Une correspondance entre le centre des mires et le repère monde est ensuite sauvegardée (c.).

Le passage du repère monde vers le repère image est réalisé de la manière suivante :

$$\begin{pmatrix} s_u \\ s_v \\ w \end{pmatrix} = \mathbf{KH} \begin{pmatrix} x_w \\ y_w \\ z_w \\ 1 \end{pmatrix} \quad (\text{A.3})$$

Les coordonnées homogènes du point \mathcal{O} dans le repère image sont finalement obtenues par :

$$\begin{pmatrix} u_{\mathcal{O}} \\ v_{\mathcal{O}} \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{s_{u_{\mathcal{O}}}}{w} \\ \frac{s_{v_{\mathcal{O}}}}{w} \\ 1 \end{pmatrix} \quad (\text{A.4})$$

Pour une description plus complète de la modélisation géométrie d'une caméra et de la géométrie projective, le lecteur pourra se référer à [Davies et Davies, 1997; Hartley, 2008]. L'estimation des paramètres intrinsèques et extrinsèques a été réalisée à l'aide de la boîte à outils de calibration développée par J. Y. Bouguet¹. La mise en œuvre de la calibration nécessite l'utilisation d'une mire (un damier) telle que représentée à la figure A.3. Plusieurs images de cette mire sont acquises avec une disposition variable de manière à permettre la résolution d'un système d'équations. Cette résolution conduit à la connaissance des paramètres intrinsèques, mais aussi au placement d'un repère monde sur chacune des mires acquises. Par conséquent, sur la dernière des acquisitions, la mire est positionnée sur le plateau et la caméra est placée en position finale (celle qui sera utilisée lors des acquisitions). De cette manière, le plan du plateau (assimilé au sol) est confondu avec le plan (X_w, Y_w) (cf. figure A.3.). C'est ce repère monde en particulier que nous avons utilisé lors de la phase d'annotation des images d'apprentissage.

La mire de calibration n'étant plus utilisée lors des acquisitions, il est nécessaire de pouvoir replacer le repère monde sur le plateau tout au long de la rotation de celui-ci. Pour cela, pendant la phase de calibration, une correspondance entre les quatre petites mires et le repère monde a été établie. Cette correspondance a tout d'abord été réalisée

¹. La boîte à outil de calibration est disponible gratuitement à l'adresse http://www.vision.caltech.edu/bouguetj/calib_doc/index.html#ref

dans le repère image (en marquant manuellement le centre des petites mires dans un ordre établi), puis dans le repère monde par reprojection (il n'y a pas d'indétermination lors de la reprojection des points image car les coordonnées z_w des petites mires dans le repère monde sont connues et égales à 0).

A.3 ACQUISITION ET ANNOTATION DES IMAGES

Une fois la caméra calibrée et le repère monde connu, chaque modèle de la base a été placé sur le plateau et une séquence d'image a été acquise pour une rotation complète du plateau. Le plateau a été manœuvré manuellement, et pour chaque classe environ 1000 images ont été acquises. Cette étape d'acquisition a précédé l'annotation de la pose des objets de chaque image de la séquence.

L'annotation de la pose a été réalisée en plusieurs étapes. Le nombre total d'images étant important (plusieurs milliers), une annotation automatique a été envisagée.

Annotation manuelle de la première image de la séquence

Pour une séquence donnée, la pose de l'objet sur la première image a été annotée manuellement de la manière suivante :

- Le repère monde défini lors de la phase de calibration a été importé (figure A.4, a.). Le plateau ayant tourné, l'étape suivante a consisté à recalibrer ce repère monde relativement aux petites mires de la même manière que pendant la calibration. Ce recalage a été effectué en annotant manuellement le centre des quatre mires sur l'image (dans le même ordre que pendant la calibration), en reprojétant leurs coordonnées dans le repère monde et en appliquant une transformation sur le repère monde (rotation d'axe Z_w et translation dans le plan ($\mathbf{X}_w, \mathbf{Y}_w$)) afin que les mires aient les mêmes coordonnées que lors de la calibration (figure A.4, b.).
- Un repère modèle ($\mathbf{X}_m, \mathbf{Y}_m, \mathbf{Z}_m$) a ensuite été placé sur la première image de manière à connaître la pose de l'objet dans le repère monde. Le placement de ce repère a été réalisé précisément à l'aide d'un modèle polyédrique positionné manuellement sur l'objet (figure A.4, c.).

Annotation automatique des images suivantes

La position relative entre les repères monde et modèle étant fixée, l'annotation des autres images de la séquence a été réalisée automatiquement de la manière suivante :

- À chaque nouvelle image, les centres des quatre petites mires ont été déterminés automatiquement par un suivi sur l'image.
- Un recalage du repère monde par rapport aux petites mires, puis du repère modèle par rapport au repère monde. La pose de l'objet relativement à la caméra est alors déduite (figure A.4, d.).




FIGURE A.4 – Exemple d'acquisition ; a. : le repère monde estimé lors de la calibration est placé, mais le plateau a tourné ; b. : le placement manuel des quatre mires (dans le même ordre que lors de la calibration) permet de recalibrer convenablement le repère monde ; c. : le repère objet est défini à l'aide d'un modèle polyédrique placé manuellement sur la première image de la séquence ; d. : annotation automatique de la séquence à partir du suivi des quatre mires et du remplacement des repères. Les quatre mires doivent rester visibles tout au long de la séquence.

PROCÉDURE DE DASVM

B

La procédure de DASVM mise en œuvre au chapitre 7 est décrite ici de manière concise. Le lecteur pourra se référer à [Bruzzone et Marconcini, 2010] pour une description plus détaillée. Les notations adoptées au chapitre 7 sont conservées.

B.1 PHASE 1 : INITIALISATION

La première phase (itération 0) consiste à déterminer un classifieur SVM $f^{(0)}(\cdot)$ à l'aide d'un ensemble de données d'apprentissage $\mathcal{A}^{(0)}$, c'est-à-dire :

$$\begin{aligned}\mathcal{A}^{(0)} &= (\mathbf{X}_S, \omega_S) = \{x_{i,S}, \omega_{i,S}\}_{i=1,\dots,N_S} \\ f^{(0)}(x) &= w^{(0)}x + b^{(0)}\end{aligned}\quad (\text{B.1})$$

B.2 PHASE 2 : ADAPTATION DE DOMAINE ITÉRATIVE

À l'itération l , deux ensembles de données cibles sont considérés. Les données cibles *non labélisées* et les données cibles *semi-labélisées*. Les données cibles non labélisées sont annotées par la classe estimée par le classifieur, i.e. $\hat{\omega}_{i,\mathcal{T}} = \text{sign}(f^{(l)}(x_{i,\mathcal{T}}))$. En particulier, les données non labélisées à l'intérieur de la marge du classifieur sont regroupées en deux sous-ensembles ordonnés :

$$\begin{aligned}\mathcal{H}_{\text{up}}^{(l)} &= \{(x_{i,\mathcal{T}}, \omega_{i,\mathcal{T}}) \mid x_{i,\mathcal{T}} \in \mathcal{X}_{\mathcal{T}}^{(l)}, 1 \geq f^{(l)}(x_{i,\mathcal{T}}) \geq f^{(l)}(x_{i+1,\mathcal{T}}) \geq 0\} \\ \mathcal{H}_{\text{low}}^{(l)} &= \{(x_{i,\mathcal{T}}, \omega_{i,\mathcal{T}}) \mid x_{i,\mathcal{T}} \in \mathcal{X}_{\mathcal{T}}^{(l)}, -1 \leq f^{(l)}(x_{i,\mathcal{T}}) \leq f^{(l)}(x_{i+1,\mathcal{T}}) < 0\}\end{aligned}\quad (\text{B.2})$$

Les n_{up} données de scores les plus grands de $\mathcal{H}_{\text{up}}^{(l)}$ (resp. les n_{low} données de scores les plus faibles de $\mathcal{H}_{\text{low}}^{(l)}$), qui sont celles susceptibles d'influencer le plus l'hyperplan séparateur actuel, sont intégrées à $\mathcal{A}^{(l)}$ et deviennent des données semi-labélisées. Dans le cas où $\text{card}(\mathcal{H}_{\text{up}}^{(l)}) < n_{\text{up}}$ (resp. $\text{card}(\mathcal{H}_{\text{low}}^{(l)}) < n_{\text{low}}$), l'ensemble $\mathcal{H}_{\text{up}}^{(l)}$ (resp. $\mathcal{H}_{\text{low}}^{(l)}$) est intégré à $\mathcal{A}^{(l)}$.

Les données semi-labélisées à l'itération précédente qui ont changé de classe suite à la mise à jour du classifieur sont considérées comme inconsistantes et redeviennent non labélisées. Plus précisément, l'ensemble

$$\mathbf{X}_{\text{incons.}}^{(l)} = \{(x_{i,\mathcal{T}}, \hat{\omega}_{i,\mathcal{T}}) \in \mathcal{A}^{(l)} \mid \hat{\omega}_{i,\mathcal{T}}^{(l-1)} \neq \hat{\omega}_{i,\mathcal{T}}^{(l)}\}$$

est exclu de $\mathcal{A}^{(l)}$.

Une partie des données sources sont éliminées de $\mathcal{A}^{(l)}$. Pour cela, deux sous-ensembles ordonnés sont considérés (selon le signe du classifieur) :

$$\begin{aligned}\mathcal{Q}_{\text{up}}^{(l)} &= \{(x_{i,S}, \omega_{i,S}) \mid x_{i,S} \in \mathcal{A}^{(l)}, f^{(l)}(x_{i,S}) \geq f^{(l)}(x_{i+1,S}) \geq 0\} \\ \mathcal{Q}_{\text{low}}^{(l)} &= \{(x_{i,S}, \omega_{i,S}) \mid x_{i,S} \in \mathcal{A}^{(l)}, f^{(l)}(x_{i,S}) \leq f^{(l)}(x_{i+1,S}) < 0\}\end{aligned}\quad (\text{B.3})$$

Les n_{up} données de scores les plus grands de $\mathcal{Q}_{\text{up}}^{(l)}$ (resp. les n_{low} données de scores les plus faibles de $\mathcal{Q}_{\text{low}}^{(l)}$), sont exclues de $\mathcal{A}^{(l)}$. Dans le cas où $\text{card}(\mathcal{Q}_{\text{up}}^{(l)}) < n_{\text{up}}$ (resp. $\text{card}(\mathcal{Q}_{\text{low}}^{(l)}) < n_{\text{low}}$), l'ensemble $\mathcal{Q}_{\text{up}}^{(l)}$ (resp. $\mathcal{Q}_{\text{low}}^{(l)}$) est exclu de $\mathcal{A}^{(l)}$.

Le classifieur est ensuite mis à jour. L'apprentissage du SVM consiste à résoudre le problème de minimisation sous contraintes suivant :

$$\begin{cases} \min_{w,b,\xi_S,\xi_T} \left\{ \frac{1}{2} \|w^{(l)}\|^2 + C_S^{(l)} \sum_i \xi_{i,S} + C_T^{(l)} \sum_i \xi_{i,T} \right\} \\ \omega_{i,S}(w^{(l)}x_{i,S} + b^{(l)}) \geq 1 - \xi_{i,S}, \quad \forall x_{i,S} \in \mathcal{A}^{(l)} \\ \widehat{\omega}_{i,T}^{(l-1)}(w^{(l)}x_{i,T} + b^{(l)}) \geq 1 - \xi_{i,T}, \quad \forall x_{i,T} \in \mathcal{A}^{(l)} \\ \xi_{i,S}, \xi_{i,T} \geq 0 \end{cases}$$

Afin de donner progressivement une importance plus grande aux données cibles semi-labélisées, le paramètre de régularisation $C_{i,T}^{(l)}$ de $x_{i,T}$ est croissant avec le nombre d'itérations k_i pendant lesquelles la donnée $x_{i,T}$ a été intégrée au jeu d'apprentissage. À l'inverse, le paramètre de régularisation $C_{i,S}^{(l)}$ est décroissant pour diminuer progressivement l'importance des données sources du jeu d'apprentissage et adapter le classifieur. L'évolution de ces paramètres est quadratique avec le nombre d'itérations, plus précisément :

$$\begin{aligned} C_{i,T}^{(l)} &= (C_{\max,T} - C_{\text{init},T}) \left(\frac{k_i - 1}{K - 1} \right)^2 + C_{\text{init},T}, \quad \forall x_{i,T} \in \mathcal{A}^{(l)}, k = 1, \dots, K \\ C_{i,S}^{(l)} &= \max \left((C_{\text{init},T} - C_{\text{init},S}) \left(\frac{l}{K} \right)^2 + C_{\text{init},S}, C_{\text{init},T} \right), \quad \forall x_{i,S} \in \mathcal{A}^{(l)} \end{aligned} \quad (\text{B.4})$$

où les termes $C_{\text{init},T}$ et $C_{\max,T}$ sont respectivement les paramètres de régularisation initial et maximal pour les données cible semi-labélisées, $C_{\text{init},S}$ est le paramètre de régularisation initial des données sources, et K est le nombre d'itérations au delà duquel les paramètres de régularisation ne sont plus mis à jour.

B.3 PHASE 3 : CRITÈRES D'ARRÊT

Le processus d'adaptation itératif prend fin si l'un des critères suivants est vérifié :

$$\begin{cases} \text{card}(\mathbf{X}_{\text{incons.}}^{(l)}) \leq \alpha N_S \\ \text{card}(\mathcal{H}_{\text{up}}^{(l)} \cup \mathcal{H}_{\text{low}}^{(l)}) \leq \alpha N_S \\ \mathcal{Q}_{\text{up}}^{(l)} \cup \mathcal{Q}_{\text{low}}^{(l)} = \emptyset \end{cases}$$

où α est un paramètre de réglage de la sensibilité de la procédure, choisi a priori. Dans notre implémentation, le paramètre $C_{\text{init},S}$ a été choisi par validation croisée d'ordre cinq. Les autres paramètres ont été fixés à $C_{\text{init},T} = 0,01$, $C_{\max,T} = 0,5$, (comme préconisé par [Bruzzone et Marconcini, 2010]), $K = 10$, $\alpha = 0,1$, et $n_{\text{up}} = n_{\text{low}} = 100$.

BIBLIOGRAPHIE

- Aguilera, J., Cipriano, A., Eraña, M., Lillo, I., Mery, D., Soto, A., et Valdivieso, C. (2007). Computer vision for quality control in latin american food industry, a case study. In *ICCV : Workshop on Computer Vision Applications for Developing Countries*, pages 1–11. IEEE Computer Society.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6) :716–723.
- Allwein, E., Schapire, R., et Singer, Y. (2001). Reducing multiclass to binary : A unifying approach for margin classifiers. *The Journal of Machine Learning Research*, 1 :113–141.
- Aloimonos, J., Weiss, I., et Bandopadhyay, A. (1987). Active vision. *International Journal on Computer Vision*, pages 333–356.
- Althoefer, K., Krekelberg, B., Husmeier, D., et Seneviratne, L. D. (2001). Reinforcement learning in a rule-based navigator for robotic manipulators. *Neurocomputing*, 37(1-4) :51–70.
- Amit, Y. et Geman, D. (1999). A computational model for visual selection. *Neural computation*, 11(7) :1691–1715.
- Amit, Y., Geman, D., et Fan, X. (2004). A coarse-to-fine strategy for multiclass shape detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 1606–1621.
- Amit, Y. et Trouvé, A. (2007). Pop : Patchwork of parts models for object recognition. *International Journal of Computer Vision*, 75(2) :267–282.
- Amores, J., Sebe, N., et Radeva, P. (2007). Class-specific binary correlograms for object recognition. In *Proceedings of the British Machine Vision Conference*. Manchester, U. K :[s. n].
- Arbel, T. et Ferrie, F. P. (2001). Entropy-based gaze planning. *Image and vision computing*, 19(11) :779–786. Elsevier.
- Arbel, T. (2000). *Active Object Recognition Conditioned by Probabilistic Evidence and Entropy Maps*. PhD thesis, McGill University, Montreal.
- Arbel, T. et Ferrie, F. P. (1999). Viewpoint selection by navigation through entropy maps. In *Proceedings of the IEEE Seventh International Conference on Computer Vision*, volume 140, pages 248–254. IEEE Computer Society.
- Arie-Nachimson, M. et Basri, R. (2009). Constructing implicit 3d shape models for pose estimation. In *Proceedings of the IEEE 12th International Conference on Computer Vision*, pages 1341–1348. IEEE Computer Society.
- Arnold, A., Nallapati, R., et Cohen, W. W. (2008). Exploiting feature hierarchy for transfer learning in named entity recognition. In *In ACL :HLT*.
- Atkeson, C. G. et Santamaria, J. C. (1997). A comparison of direct and model-based reinforcement learning. In *Proceedings of the IEEE International Conference on Robotics and Automation*, pages 3557–3564. IEEE Computer Society.
- Atkeson, C. G. et Schaal, S. (1997). Robot learning from demonstration. In *Proceedings of the International Conference for Machine Learning*, pages 12–20.
- Bajcsy, R. (1988). Active perception. *Proceedings of the IEEE*, 76(8) :966–1005.
- Ballard, D. (1991). Animate vision. *Artificial intelligence*, 48(1) :57–86.
- Bart, E., Byvatov, E., et Ullman, S. (2004). View-invariant recognition using corresponding object fragments. *European Conference on Computer Vision*, pages 152–165.
- Baumberg, A. (2000). Reliable feature matching across widely separated views. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, page 1774. IEEE Computer Society.
- Bellman, R. E. (1957). *Dynamic Programming*. Princeton University Press, Princeton, USA.

- Bellman, R. E. (1961). *Adaptive control processes - A guided tour*. Princeton University Press, Princeton, USA.
- Belongie, S., Malik, J., et Puzicha, J. (2001). Matching shapes. In *Proceedings of the IEEE Eighth International Conference on Computer Vision*, volume 1, pages 454–461. IEEE Computer Society.
- Ben-David, S., Blitzer, J., Crammer, K., et Pereira, F. (2007). Analysis of representations for domain adaptation. In *Proceedings of the conference on Advances in Neural Information Processing Systems*. MIT Press.
- Berg, A., Berg, T., et Malik, J. (2005). Shape matching and object recognition using low distortion correspondences. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 26–33. IEEE Computer Society.
- Berg, A. et Malik, J. (2001). Geometric blur for template matching. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, page 607. IEEE Computer Society.
- Bertsekas, D. P. (2005). *Dynamic Programming and Optimal Control*. 2nd ed., Athena Scientific, Belmont, USA.
- Bertsekas, D. P. et Tsitsiklis, J. N. (1996). *Neuro-Dynamic Programming*. Athena Scientific, Belmont, USA.
- Biederman, I. (1987). Recognition-by-components : A theory of human image understanding. *Psychological review*, 94(2) :115.
- Bishop, C. (2006). *Pattern recognition and machine learning*, volume 4. Springer New York.
- Blanchard, G. et Geman, D. (2005). Hierarchical testing designs for pattern recognition. *The Annals of Statistics*, 33(3) :1155–1202.
- Blitzer, J., McDonald, R., et Pereira, F. (2006). Domain adaptation with structural correspondence learning. In *Proceedings of the 2006 Conference on Empirical Methods in Natural Language Processing*, pages 120–128, Sydney, Australia. Association for Computational Linguistics.
- Bloch, I. (1996). Information combination operators for data fusion : A comparative review with classification. *IEEE Transactions on Systems, Man and Cybernetics, Part A : Systems and Humans*, 26(1) :52–67.
- Blum, A. et Langley, P. (1997). Selection of relevant features and examples in machine learning. *Artificial intelligence*, 97(1-2) :245–271.
- Boone, G. (2002). Efficient reinforcement learning : Model-based acrobot control. In *Proceedings of the IEEE International Conference on Robotics and Automation*, volume 1, pages 229–234. IEEE Computer Society.
- Borotschnig, H., Paletta, L., et Pinz, A. (1999). A comparison of probabilistic, possibilistic and evidence theoretic fusion schemes for active object recognition. *Computing*, 62(4) :293–319.
- Borotschnig, H., Paletta, L., Prantl, M., et Pinz, A. (1998). Active object recognition in parametric eigenspace. In *In Proceedings of the 9th British Machine Vision Conference*, pages 629–638. Manchester, U. K :[s. n].
- Borotschnig, H., Paletta, L., Prantl, M., et Pinz, A. (2000). Appearance-based active object recognition. *Image and Vision Computing*, 18(9) :715–727.
- Bosch, A., Zisserman, A., et Munoz, X. (2007). Representing shape with a spatial pyramid kernel. In *Proceedings of the 6th ACM international conference on Image and video retrieval*, pages 401–408. ACM.
- Bouchard, G. et Triggs, B. (2004). The tradeoff between generative and discriminative classifiers. In *IASC International Symposium on Computational Statistics (COMPSTAT)*, pages 721–728. Citeseer.
- Bousquet, O., Boucheron, S., et Lugosi, G. (2004). Introduction to statistical learning theory. *Advanced Lectures on Machine Learning*, pages 169–207.
- Boutell, M., Luo, J., Shen, X., et Brown, C. (2004). Learning multi-label scene classification. *Pattern Recognition*, 37(9) :1757–1771.
- Bowyer, K. et Dyer, C. (1990). Aspect graphs : An introduction and survey of recent results. *International Journal of Imaging Systems and Technology*, 2(4) :315–328.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 26 :123–140.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1) :5–32.
- Breiman, L., Friedman, J. H., Olshen, R., et Stone, C. J. (1984). *Classification and Regression Trees*. Wadsworth, Belmont, California.

- Brochu, E., Cora, V. M., et de Freitas, N. (2009). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. Technical Report TR-2009-23, Department of Computer Science, University of British Columbia.
- Brown, C. (1981). Some mathematical and representational aspects of solid modeling. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (4) :444–453.
- Brown, R. (1958). How shall a thing be called? *Psychological Review*, 65(1) :14.
- Brucker, F., Benites, F., et Sapozhnikova, E. (2010). Multi-label classification and extracting predicted class hierarchies. *Pattern Recognition*.
- Bruzzone, L. et Marconcini, M. (2010). Domain adaptation problems : a dasvm classification technique and a circular validation strategy. *IEEE transactions on pattern analysis and machine intelligence*, 32(5) :770–787.
- Bülthoff, H. et Edelman, S. (1992). Psychophysical support for a two-dimensional view interpolation theory of object recognition. *Proceedings of the National Academy of Sciences*, 89(1) :60.
- Burl, M., Weber, M., et Perona, P. (1998). A probabilistic approach to object recognition using local photometry and global geometry. *European Conference on Computer Vision*, pages 628–641.
- Burns, J., Weiss, R., et Riseman, E. (1992). The non-existence of general-case view-invariants. *Geometric invariance in computer vision*, pages 120–131.
- Burred, J. et Lerch, A. (2003). A hierarchical approach to automatic musical genre classification. In *Proceedings of the 6th International Conference on Digital Audio Effects*. DAFX.
- Callari, F. et Ferrie, F. (1996a). Active recognition : Using uncertainty to reduce ambiguity. In *Proceedings of the IEEE 13th International Conference on Pattern Recognition, 1996*, volume 1, pages 925–929. IEEE Computer Society.
- Callari, F. et Ferrie, F. (1996b). Autonomous recognition : driven by ambiguity. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, page 701. IEEE Computer Society.
- Campbell, R. et Flynn, P. (2001). A survey of free-form object representation and recognition techniques. *Computer Vision and Image Understanding*, 81(2) :166–210.
- Canny, J. (1987). A computational approach to edge detection. *Readings in computer vision : issues, problems, principles, and paradigms*, 184 :87–116.
- Carneiro, G. et Lowe, D. (2006). Sparse flexible models of local features. *European Conference on Computer Vision*, pages 29–43.
- Cesa-Bianchi, N., Gentile, C., et Zaniboni, L. (2006). Hierarchical classification : combining bayes with svm. In *Proceedings of the 23rd International Conference on Machine Learning*, pages 177–184. ACM.
- Chen, S., Zhang, J., et Wang, W. (2008). *Active sensor planning for multiview vision tasks*. Springer Verlag.
- Chen, Y., Crawford, M., et Ghosh, J. (2004). Integrating support vector machines in a hierarchical output space decomposition framework. In *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium, 2004*, volume 2, pages 949–952. IEEE Computer Society.
- Cléménçon, S. et Vayatis, N. (2009). Tree-based ranking methods. *IEEE Transactions on Information Theory*, 55(9) :4316–4336.
- Cléménçon, S., Vayatis, N., et Depecker, M. (2009). Auc optimization and the two-sample problem. In Bengio, Y., Schuurmans, D., Lafferty, J., Williams, C. K. I., et Culotta, A., editors, *Proceedings of the Conference on Advances in Neural Information Processing Systems*, pages 360–368. MIT Press.
- Cootes, T., Wheeler, G., Walker, K., et Taylor, C. (2002). View-based active appearance models. *Image and Vision Computing*, 20(9-10) :657–664.
- Cover, T., Thomas, J., Wiley, J., et al. (1991). *Elements of information theory*, volume 306. Wiley Online Library.
- Crammer, K. et Singer, Y. (2002). On the algorithmic implementation of multiclass kernel-based vector machines. *The Journal of Machine Learning Research*, 2 :265–292.
- Crandall, D., Felzenszwalb, P., et Huttenlocher, D. (2006). Object recognition by combining appearance and geometry. *Toward category-level object recognition*, pages 462–482. Springer.

- Csurka, G., Dance, C., Fan, L., Willamowski, J., et Bray, C. (2004). Visual categorization with bags of keypoints. In *Workshop on statistical learning in computer vision, ECCV*, volume 1, page 22. Citeseer.
- Da, F. et Zhang, H. (2010). Sub-pixel edge detection based on an improved moment. *Image and Vision Computing*, 28(12) :1645–1658.
- Dai, W., Chen, Y., Xue, G.-R., Yang, Q., et Yu, Y. (2008). Translated learning : Transfer learning across different feature spaces. In *Proceedings of the conference on Advances in Neural Information Processing Systems*, pages 353–360. MIT Press.
- Dai, W., Yang, Q., rong Xue, G., et Yu, Y. (2007). Boosting for transfer learning. In *Proceedings of the International Conference on Machine Learning*. ACM.
- Dalal, N. et Triggs, B. (2005). Histograms of oriented gradients for human detection. volume 1, pages 886–893.
- Dasarathy, B. V. (1990). *Nearest neighbor (NN) norms : NN pattern classification techniques*.
- Davies, E. et Davies, E. (1997). *Machine vision : theory, algorithms, practicalities*. Academic press London.
- Dearden, R., Friedman, N., et Andre, D. (1999). Model based bayesian exploration. In *Proceedings of the 15th Conference on Uncertainty in Artificial Intelligence*, pages 150–159.
- Dearden, R., Friedman, N., et Russell, S. (1998). Bayesian q-learning. In *Proceedings of the 15th National Conference on Artificial Intelligence*, pages 761–768.
- Decoste, D. et Schölkopf, B. (2002). Training invariant support vector machines. *Machine Learning*, 46(1-3) :161–190.
- Deinzer, F., Denzler, J., et Niemann, H. (2000). Classifier independent viewpoint selection for 3-d object recognition. In *Mustererkennung 2000*, pages 237–244. Springer.
- Deinzer, F., Denzler, J., et Niemann, H. (2001). On fusion of multiple views for active object recognition. *Pattern Recognition*, pages 239–245.
- Deisenroth, M. P., Peters, J., et Rasmussen, C. E. (2008). Approximate dynamic programming with gaussian processes. In *Proceedings of the American Control Conference*, pages 4480–4485.
- Deisenroth, M. P., Rasmussen, C. E., et Peters, J. (2009). Gaussian process dynamic programming. *Neurocomputing*, 72(7-9) :1508–1524.
- Dempster, A., Laird, N., et Rubin, D. (1977). Maximum likelihood from incomplete data via the em algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, 39(1) :1–38.
- Denzler, J. et Brown, C. (2000). Optimal selection of camera parameters for state estimation of static systems : An information theoretic approach. Technical report.
- Denzler, J. et Brown, C. M. (2002). Information theoretic sensor data selection for active object recognition and state estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(2) :145–157.
- Deriche, R. (1990). Fast algorithms for low-level vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 78–87.
- Derichs, C., Deinzer, F., et Niemann, H. (2005). Cost integration in multi-step viewpoint selection for object recognition. *Machine Learning and Data Mining in Pattern Recognition*, pages 415–425.
- Deselaers, T., Heigold, G., et Ney, H. (2010). Object classification by fusing svms and gaussian mixtures. *Pattern Recognition*, 43(7) :2476–2484.
- Dickinson, S., Pentland, A., et Rosenfeld, A. (1992). 3-d shape recovery using distributed aspect matching. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 174–198.
- Dietterich, T. et Bakiri, G. (1995). Solving multiclass learning problems via error-correcting output codes. *Journal of Artificial Intelligence Research*, 2(263) :286.
- Dorkó, G. et Schmid, C. (2003). Selection of scale-invariant parts for object class recognition. In *Proceedings of the IEEE Ninth International Conference on Computer Vision*, pages 634–639. IEEE Computer Society.
- Duda, R., Hart, P., et Stork, D. (2001). *Pattern classification*, volume 2. Wiley, New York.
- Dumais, S. et Chen, H. (2000). Hierarchical classification of web content. In *Proceedings of the 23rd annual International Conference on Research and Development in Information Retrieval*, pages 256–263. ACM.

- Dutta, S., Chaudhury, S., et Banerjee, S. (2004). Active recognition through next view planning : a survey. *Pattern Recognition*, 37(3) :429–446.
- Edelman, S. (1997). Computational theories of object recognition. *Trends in Cognitive Sciences*, 1(8) :296–304.
- Engel, Y., Mannor, S., et Meir, R. (2005). Reinforcement learning with gaussian processes. In *Proceedings of the 22nd International Conference on Machine learning*, pages 201–208. ACM.
- Epshtein, B. et Ullman, S. (2005a). Feature hierarchies for object classification.
- Epshtein, B. et Ullman, S. (2005b). Identifying semantically equivalent object fragments. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 2–9, Washington, DC, USA. IEEE Computer Society.
- Epshtein, B. et Ullman, S. (2006). Satellite features for the classification of visually similar classes. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2079–2086, Washington, DC, USA. IEEE Computer Society.
- Evans, A., Thacker, N., et Mayhew, J. (1993). The use of geometric histograms for model-based object recognition. In *Proceedings of the 4th British Machine Vision Conference*, pages 429–438. Manchester, U. K :[s. n].
- Everingham, M. and Van Gool, L. and Williams, C.K.I. and Winn, J. and Zisserman, A. (2010). The PASCAL visual object classes (VOC) challenge. *International Journal of Computer Vision*, 88(2) :303–338. Kluwer Academic Publishers.
- Farhadi, A., Tabrizi, M., Endres, I., et Forsyth, D. (2009). A latent model of discriminative aspect. In *Proceedings of the IEEE 12th International Conference on Computer Vision*, pages 948–955. IEEE Computer Society.
- Faugeras, O., Mundy, J., Ahuja, N., Dyer, C., Pentland, A., Jain, R., Ikeuchi, K., et Bowyer, K. (1992). Why aspect graphs are not (yet) practical for computer vision. *CVGIP : Image Understanding*, 55(2) :212–218.
- Fei-Fei, L., Fergus, R., et Perona, P. (2006). One-shot learning of object categories. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(4) :594–611.
- Felzenszwalb, P. et Huttenlocher, D. (2005). Pictorial structures for object recognition. *International Journal of Computer Vision*, 61(1) :55–79.
- Fergus, R., Perona, P., et Zisserman, A. (2005). A sparse object category model for efficient learning and exhaustive recognition. In *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*, volume 1, pages 380–387. IEEE Computer Society.
- Fergus, R., Perona, P., Zisserman, A., et Ox (2003). Object class recognition by unsupervised scale-invariant learning. In *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*, volume 2, pages 264–271. IEEE Computer Society.
- Ferrari, V., Fevrier, L., Jurie, F., et Schmid, C. (2008). Groups of adjacent contour segments for object detection. *IEEE transactions on pattern analysis and machine intelligence*, 30(1) :36–51.
- Ferrari, V., Tuytelaars, T., et Van Gool, L. (2006). Simultaneous object recognition and segmentation from single or multiple model views. *International Journal of Computer Vision*, 67(2) :159–188.
- Findlay, J. et Gilchrist, I. (2003). *Active vision : The psychology of looking and seeing*. Oxford University Press.
- Fischler, M. et Elschlager, R. (1973). The representation and matching of pictorial structures. *IEEE Transactions on Computers*, 100(1) :67–92.
- Fisher, R. (1936). The use of multiple measurements in taxonomic problems. *Annals of Human Genetics*, 7(2) :179–188.
- Fleuret, F. (2004). Fast binary feature selection with conditional mutual information. *The Journal of Machine Learning Research*, 5 :1531–1555.
- Forsyth, D., Mundy, J., Zisserman, A., Coelho, C., Heller, A., et Rothwell, C. (1991). Invariant descriptors for 3d object recognition and pose. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(10) :971–991.
- Forsyth, D. et Ponce, J. (2002). *Computer vision : a modern approach*. Prentice Hall Professional Technical Reference.
- Freeman, W. et Adelson, E. (1991). The design and use of steerable filters. *IEEE Transactions on Pattern analysis and machine intelligence*, 13(9) :891–906.

- Friedman, J. (1998). Data mining and statistics : What's the connection ? *Computing Science and Statistics*, pages 3–9.
- Friedman, J. (2001). Greedy function approximation : a gradient boosting machine. *The Annals of Statistics*, 29(5) :1189–1232.
- Furber, S. et Brown, A. (2009). Biologically-inspired massively-parallel architectures-computing beyond a million processors. In *Ninth International Conference on Application of Concurrency to System Design*, pages 3–12. IEEE Computer Society.
- Fürnkranz, J., Hüllermeier, E., Loza Mencía, E., et Brinker, K. (2008). Multilabel classification via calibrated label ranking. *Machine learning*, 73(2) :133–153.
- Gabel, T. et Riedmiller, M. (2007). Adaptive reactive job-shop scheduling with learning agents. 24(4).
- Gavrila, D. (1999). The visual analysis of human movement : A survey. *Computer vision and image understanding*, 73(1) :82–98.
- Genuer, R., Poggi, J., et Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern Recognition Letters*, 31(14) :2225–2236.
- Ghavamzadeh, M. et Engel, Y. (2007). Bayesian policy gradient algorithms. *Proceedings of the conference on Advances in Neural Information Processing Systems*, 19 :457–464.
- Giachetti, A., Campani, M., et Torre, V. (1998). The use of optical flow for road navigation. *IEEE Transactions on Robotics and Automation*, 14(1) :34–48.
- Gibson, J. (1968). What gives rise to the perception of motion ? *Psychological Review*, 75(4) :335.
- Gordon, A. (1987). A review of hierarchical classification. *Journal of the Royal Statistical Society. Series A (General)*, 150(2) :119–137.
- Grimson, W. et al. (1990). Object recognition by computer : the role of geometric constraints.
- Guinet, J. (2008). *Reconnaissance multi-vues de véhicules sur séquences d'images*. PhD thesis, Université de Cergy-Pontoise, France.
- Gupte, S., Masoud, O., Martin, R., et Papanikolopoulos, N. (2002). Detection and classification of vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 3(1) :37–47.
- Guyon, I. et Elisseeff, A. (2003). An introduction to variable and feature selection. *The Journal of Machine Learning Research*, 3 :1157–1182.
- Hadjidemetriou, E., Grossberg, M., et Nayar, S. (2004). Multiresolution histograms and their use for recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(7) :831–847.
- Harchaoui, Z. et Bach, F. (2007). Image classification with segmentation graph kernels. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–8. IEEE Computer Society.
- Hardin, D., Tsamardinos, I., et Aliferis, C. (2004). A theoretical characterization of linear svm-based feature selection. In *Proceedings of the twenty-first International Conference on Machine Learning*, page 48. ACM.
- Harman, K., Keith Humphrey, G., et Goodale, M. (1999). Active manual control of object views facilitates visual recognition. *Current Biology*, 9(22) :1315–1318.
- Harris, C. et Stephens, M. (1988). A combined corner and edge detector. In *Alvey vision conference*, volume 15, page 50. Manchester, UK.
- Hartley, R. (2008). *Multiple view geometry in computer vision*. Cambridge university press.
- Hastie, T. et Tibshirani, R. (1998). Classification by pairwise coupling. *The annals of statistics*, 26(2) :451–471.
- Hastie, T., Tibshirani, R., et Friedman, J. (2009). *The elements of statistical learning : data mining, inference, and prediction*. Springer Verlag.
- Heisele, B., Serre, T., Pontil, M., Vetter, T., et Poggio, T. (2002). Categorization by learning and combining object parts. In Dietterich, T. G., Becker, S., et Ghahramani, Z., editors, *Proceedings of the conference on Advances in Neural Information Processing Systems*, pages 1239–1245, Cambridge, MA. MIT Press.
- Herbin, S. (1996). Recognizing 3d objects by generating random actions. In *Proceedings of the Conference on Computer Vision and Pattern Recognition*, pages 35–40. IEEE Computer Society.

- Herbin, S. (1997). *Éléments pour la formalisation d'une reconnaissance active. Application à la vision tri-dimensionnelle*. PhD thesis, ENS-Cachan, France.
- Herbin, S. (1998). Combining geometric and probabilistic structure for active recognition of 3d objects. *European Conference on Computer Vision*, pages 748–764.
- Herbin, S. (2003). Active sampling strategies for multihypothesis testing. In *Energy minimization methods in computer vision and pattern recognition : 4th international workshop*, page 97. Springer Verlag.
- Ho, T., Hull, J., et Srihari, S. (1994). Decision combination in multiple classifier systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(1) :66–75.
- Horn, R.A. et Johnson, C.R. (1990). *Matrix analysis*. Cambridge University Press.
- Huang, C., Camps, O., et Kanungo, T. (1997). Object recognition using appearance-based parts and relations. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 877–883. IEEE Computer Society.
- Huttenlocher, D. et Ullman, S. (1987). Object recognition using alignment. In *Proceedings of the IEEE International Conference on Computer Vision*, volume 87, pages 102–111. IEEE Computer Society.
- Huttenlocher, D. et Ullman, S. (1990). Recognizing solid objects by alignment with an image. *International Journal of Computer Vision*, 5(2) :195–212.
- Isard, M. et Blake, A. (1998). Condensation-conditional density propagation for visual tracking. *International journal of computer vision*, 29(1) :5–28.
- Jaakkola, T. et Haussler, D. (1999). Exploiting generative models in discriminative classifiers. *Advances in neural information processing systems*, pages 487–493.
- Jain, A., Duin, R., et Mao, J. (2000). Statistical pattern recognition : A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1) :4–37.
- Jarvis, R. A. (1983). A perspective on range finding techniques for computer vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 5(2) :122–139. IEEE Computer Society.
- Jegou, H., Harzallah, H., et Schmid, C. (2007). A contextual dissimilarity measure for accurate and efficient image search. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–8. IEEE Computer Society.
- Johnson, A. et Hebert, M. (1997). Recognizing objects by matching oriented points. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, page 684. IEEE Computer Society.
- Jolliffe, I. (2002). Principal component analysis.
- Jones, D. R. (2001). A taxonomy of global optimization methods based on response surfaces. *Journal of Global Optimization*, 21(4) :345–383.
- Jones, D. R., Schonlau, M., et Welch, W. J. (1998). Efficient global optimization of expensive black-box functions. *Journal of Global optimization*, 13(4) :455–492.
- Jung, C., Seo, H., et Kang, H. (2010). Estimating redundancy information of selected features in multi-dimensional pattern classification. *Pattern Recognition Letters*.
- Jurie, F. et Schmid, C. (2004). Scale-invariant shape features for recognition of object categories. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 2, pages II–90. IEEE Computer Society.
- Jurie, F. et Triggs, B. (2005). Creating efficient codebooks for visual recognition. In *Proceedings of the IEEE Tenth International Conference on Computer Vision*, volume 1, pages 604–610. IEEE Computer Society.
- Kadir, T. et Brady, M. (2001). Saliency, scale and image description. *International Journal of Computer Vision*, 45(2) :83–105.
- Kadir, T. et Brady, M. (2003). Scale saliency : A novel approach to salient feature and scale selection. In *International Conference on Visual Information Engineering*, pages 25–28. IET.
- Kamada, T. et Kawai, S. (1988). A simple method for computing general position in displaying three-dimensional objects. *Computer Vision, Graphics, and Image Processing*, 41(1) :43–56.

- Kappen, H., Nijman, M., et van Moorsel, T. (1995). Learning active vision. *Industrial applications of neural networks*, page 193.
- Ke, Y. et Sukthankar, R. (2004). Pca-sift : A more distinctive representation for local image descriptors. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society.
- Kelly, A. et Stentz, A. (1998). Rough terrain autonomous mobility-part 2 : An active vision, predictive control approach. *Autonomous Robots*, 5(2) :163–198.
- Khammari, A., Nashashibi, F., Abramson, Y., et Laugeau, C. (2005). Vehicle detection combining gradient analysis and adaboost classification. In *Proceedings of the IEEE Conference on Intelligent Transportation Systems*, pages 66–71. IEEE Computer Society.
- Khan, S., Yan, P., et Shah, M. (2007). A homographic framework for the fusion of multi-view silhouettes. In *Proceedings of the IEEE 11th International Conference on Computer Vision*, pages 1–8. IEEE Computer Society.
- Kifer, D., Ben-David, S., et Gehrke, J. (2004). Detecting change in data streams. In *Proceedings of the Thirtieth international conference on Very Large Data Bases*, pages 180–191. VLDB Endowment.
- Kim, Z. et Malik, J. (2003). Fast vehicle detection with probabilistic feature grouping and its application to vehicle tracking. In *Proceedings of the IEEE Ninth International Conference on Computer Vision*, pages 524–531. IEEE Computer Society.
- Kittler, J., Hatef, M., Duin, R., et Matas, J. (1998). On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3) :226–239.
- Gluckner, S., Pacher, G., Grabner, H., Bischof, H., et Bauer, J. (2007). A 3d teacher for car detection in aerial images. In *Proceedings of the IEEE 11th International Conference on Computer Vision*, pages 1–8. IEEE Computer Society.
- Koenderink, J. (1984). The structure of images. *Biological cybernetics*, 50(5) :363–370.
- Koenderink, J. et Doorn, A. (1979). The internal representation of solid shape with respect to vision. *Biological cybernetics*, 32(4) :211–216.
- Koller, D., Daniilidis, K., et Nagel, H. (1993). Model-based object tracking in monocular image sequences of road traffic scenes. *International Journal of Computer Vision*, 10(3) :257–281.
- Koller, D., Weber, J., et Malik, J. (1994). Robust multiple car tracking with occlusion reasoning. *European Conference on Computer Vision*, pages 189–196.
- Kollnig, H. et Nagel, H. (1995). 3d pose estimation by fitting image gradients directly to polyhedral models. In *Proceedings of the International Conference on Computer Vision*, page 569. IEEE Computer Society.
- Konda, V. R. et Tsitsiklis, J. N. (2003). On actor-critic algorithms. *SIAM Journal on Control and Optimization*, 42(4) :1143–1166.
- Kovacic, S., Leonardis, A., et Pernus, F. (1998). Planning sequences of views for 3-d object recognition and pose determination. *Pattern Recognition*, 31 :1417.
- Kraskov, A., Stögbauer, H., et Grassberger, P. (2004). Estimating mutual information. *Physical Review E*, 69(6) :066138.
- Kulis, B., Saenko, K., et Darrell, T. (2011). What you saw is not what you get : Domain adaptation using asymmetric kernel transforms. In *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pages 1785–1792. IEEE Computer Society.
- Kumar, S., Ghosh, J., et Crawford, M. (2002). Hierarchical fusion of multiple classifiers for hyperspectral data analysis. *Pattern Analysis and Applications*, 5(2) :210–220.
- Lamdan, Y. (1988). Geometric hashing : A general and efficient model-based recognition scheme. In *Proceedings of the Second International Conference on Computer Vision*, pages 238–249. IEEE Computer Society.
- Laporte, C., Brooks, R., et Arbel, T. (2004). A fast discriminant approach to active object recognition and pose estimation. In *Proceedings of the IEEE 17th International Conference on Pattern Recognition*, pages 1051–1055.
- Laptev, I. (2006). Improvements of object detection using boosted histograms. In *Proceedings of the British Machine Vision Conference*, volume 3, pages 949–958. Manchester, U. K :[s. n].
- Lazebnik, S., Schmid, C., et Ponce, J. (2004). Semi-local affine parts for object recognition. In *Proceedings of the British machine vision conference*, volume 2, pages 959–968. Manchester, U. K :[s. n].

- Lazebnik, S., Schmid, C., et Ponce, J. (2006). Beyond bags of features : Spatial pyramid matching for recognizing natural scene categories. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 2, pages 2169–2178. IEEE Computer Society.
- LeCun, Y., Huang, F., et Bottou, L. (2004). Learning methods for generic object recognition with invariance to pose et lighting. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 2. IEEE Computer Society.
- Leibe, B., Ettl, A., et Schiele, B. (2008). Learning semantic object parts for object categorization. *Image and Vision Computing*, 26(1) :15–26.
- Leibe, B., Leonardis, A., et Schiele, B. (2004). Combined object categorization and segmentation with an implicit shape model. In *Workshop on Statistical Learning in Computer Vision, ECCV*, pages 17–32. Citeseer.
- Leung, C., Huang, S., Dissanayake, G., et Furukawa, T. (2005). Trajectory planning for multiple robots in bearing-only target localisation. In *Proceedings of the IEEE Conference on Intelligent Robots and Systems*, pages 3978–3983.
- Levi, K. et Weiss, Y. (2004). Learning object detection from a small number of examples : The importance of good features. In *Proceedings of the IEEE Computer Vision and Pattern Recognition*, volume 2, page 53. IEEE Computer Society.
- Li, W., Bebis, G., et Bourbakis, N. (2008). 3-d object recognition using 2-d views. *IEEE Transactions on Image Processing*, 17(11) :2236–2255.
- Li, Y., Gu, L., et Kanade, T. (2009). A robust shape model for multi-view car alignment. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2466–2473. IEEE Computer Society.
- Lindeberg, T. (1993). *Scale-space theory in computer vision*. Springer.
- Lindeberg, T. (1998). Feature detection with automatic scale selection. *International Journal of Computer Vision*, 30(2) :79–116.
- Lindeberg, T. et Garding, J. (1997). Shape-adapted smoothing in estimation of 3-d shape cues from affine deformations of local 2-d brightness structure. *Image and vision computing*, 15(6) :415–434.
- Ling, H. et Jacobs, D. (2005). Deformation invariant image matching. In *Proceedings of the IEEE Tenth International Conference on Computer Vision*, volume 2, pages 1466–1473. IEEE Computer Society.
- Liu, C. et Wechsler, H. (2002). Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition. *IEEE Transactions on Image Processing*, 11(4) :467–476.
- Liu, H., Sun, J., et Liuand Huijie, L. (2009). Feature selection with dynamic mutual information. *Pattern Recognition*, 42(7) :1330–1339.
- Liu, Y., Zhang, D., Lu, G., et Ma, W. (2007). A survey of content-based image retrieval with high-level semantics. *Pattern Recognition*, 40(1) :262–282.
- Lizotte, D., Wang, T., Bowling, M., et Schuurmans, D. (2007). Automatic gait optimization with gaussian process regression. In *Proceedings of the 20th international joint conference on Artificial intelligence*, pages 944–949.
- Logothetis, N., Pauls, J., Bülthoff, H., et Poggio, T. (1994). View-dependent object recognition by monkeys. *Current biology*, 4(5) :401–414.
- Logothetis, N. et Sheinberg, D. (1996). Visual object recognition. *Annual review of neuroscience*, 19(1) :577–621.
- Lopez-Molina, C., Bustince, H., Fernandez, J., Couto, P., et De Baets, B. (2010). A gravitational approach to edge detection based on triangular norms. *Pattern Recognition*, 43(11) :3730–3741.
- Lowe, D. (1987). Three-dimensional object recognition from single two-dimensional images. *Artificial intelligence*, 31(3) :355–395.
- Lowe, D. (1991). Fitting parameterized three-dimensional models to images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 441–450.
- Lowe, D. (1999). Object recognition from local scale-invariant features. In *Proceedings of the IEEE International Conference on computer Vision*, page 1150. IEEE Computer Society.
- Lowe, D. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2) :91–110.

- Lu, D. et Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5) :823–870.
- Lynn Beus, H. et Tiu, S. (1987). An improved corner detection algorithm based on chain-coded plane curves. *Pattern Recognition*, 20(3) :291–296.
- van der Maaten, L., Postma, E. et van den Herik, J. (2009) Dimensionality Reduction : A Comparative Review. *Journal of Machine Learning Research*, volume 10, pages 1–41.
- MacQueen, J. et al. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, page 14.
- Macrini, D., Shokoufandeh, A., Dickinson, S., Siddiqi, K., et Zucker, S. (2002). View-based 3-d object recognition using shock graphs. In *Proceedings of the IEEE 16th International Conference on Pattern Recognition*, volume 3, pages 24–28. IEEE Computer Society.
- Madzarov, G., Gjorgjevikj, D., et Chorbev, I. (2009). A multi-class svm classifier utilizing binary decision tree. *Informatica : An International Journal of Computing and Informatics*, 33(2) :225–233.
- Malis, E. (2002). Survey of vision-based robot control. *ENSIETA European Naval Ship Design Short Course, Brest, France*.
- Marchand, É. et Chaumette, F. (1999). An autonomous active vision system for complete and accurate 3d scene reconstruction. *International Journal of Computer Vision*, 32(3) :171–194.
- Marée, R., Geurts, P., Piater, J., et Wehenkel, L. (2004). A generic approach for image classification based on decision tree ensembles and local sub-windows. In *Proceedings of the 6th Asian Conference on Computer Vision*, volume 2, pages 860–865.
- Marr, D. (1983). *Vision : A computational investigation into the human representation and processing of visual information*.
- Marszalek, M. et Schmid, C. (2007). Semantic hierarchies for visual object recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–7. IEEE Computer Society.
- Martín, J. A., de Lope, J., et Maravall, D. (2010). Robust high performance reinforcement learning through weighted k-nearest neighbors. *Neurocomputing*.
- Martínez, A. M. (2002). Recognizing imprecisely localized, partially occluded, and expression variant faces from a single sample per class. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(6) :748–763.
- Martinez-Cantin, R., de Freitas, N., Brochu, E., Castellanos, J., et Doucet, A. (2009). A bayesian exploration-exploitation approach for optimal online sensing and planning with a visually guided mobile robot. *Autonomous Robots - Special Issue on Robot Learning, Part B*, 27(3) :93–103.
- Matas, J., Chum, O., Urban, M., et Pajdla, T. (2004). Robust wide-baseline stereo from maximally stable extremal regions. *Image and Vision Computing*, 22(10) :761–767.
- McLachlan, G. et Peel, D. (2000). *Finite mixture models*, volume 299. Wiley-Interscience.
- Medioni, G. et Yasumoto, Y. (1987). Corner detection and curve representation using cubic b-splines. *Computer Vision, Graphics, and Image Processing*, 39(3) :267–278.
- Mei, L., Sun, M., Carter, K., Hero, I., et Savarese, S. (2009). *Unsupervised Object Pose Classification from Short Video Sequences*. Citeseer.
- Mikolajczyk, K. et Schmid, C. (2001). Indexing based on scale invariant interest points. In *Proceedings of the IEEE Eighth International Conference on Computer Vision*, volume 1, pages 525–531. IEEE Computer Society.
- Mikolajczyk, K. et Schmid, C. (2004). Scale and affine invariant interest point detectors. *International Journal of Computer Vision*, 60(1) :63–86.
- Mikolajczyk, K. et Schmid, C. (2005). A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(10) :1615–1630.
- Miller, E. G., Matsakis, N. E., et Viola, P. A. (2000). Learning from one example through shared densities on transforms. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1 :1464+.
- Moghaddam, B. et Pentland, A. (1997). Probabilistic visual learning for object representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7) :696–710.

- Moosmann, F., Larlus, D., et Jurie, F. (2006). Learning saliency maps for object categorization. In *ECCV International Workshop on The Representation and Use of Prior Knowledge in Vision*.
- Moosmann, F., Triggs, B., et Jurie, F. (2007). Fast discriminative visual codebooks using randomized clustering forests. *Proceedings of the conference on Advances in Neural Information Processing Systems*, 19 :985.
- Moreels, P., Maire, M., et Perona, P. (2004). Recognition by probabilistic hypothesis construction. *European Conference on Computer Vision*, pages 55–68.
- Moreels, P. et Perona, P. (2007). Evaluation of features detectors and descriptors based on 3d objects. *International Journal of Computer Vision*, 73(3) :263–284.
- Moreels, P. et Perona, P. (2008). A probabilistic cascade of detectors for individual object recognition. *European Conference on Computer Vision*, pages 426–439.
- Morejon, R. et Principe, J. (2004). Advanced search algorithms for information-theoretic learning with kernel-based estimators. *IEEE Transactions on Neural Networks*, 15(4) :874–884.
- Moses, Y. et Ullman, S. (1992). Limitations of non model-based recognition schemes. In *European Conference on Computer Vision*, pages 820–828. Springer.
- Muller, K., Mika, S., Ratsch, G., Tsuda, K., et Scholkopf, B. (2001). An introduction to kernel-based learning algorithms. *IEEE Transactions on Neural Networks*, 12(2) :181–201.
- Murray-Smith, R. et Sbarbaro, D. (2002). Nonlinear adaptive control using nonparametric gaussian process prior models. In *Proceedings of the 15th IFAC World Congress on Automatic Control, Barcelona, Spain*.
- Mutch, J. et Lowe, D. (2006). Multiclass object recognition with sparse, localized features.
- Nayar, S., Murase, H., et Nene, S. (1996). Parametric appearance representation. In *Early Visual Learning*, pages 131–160.
- Nelson, R. et Selinger, A. (1998). A cubist approach to object recognition. In *Proceedings of the Sixth International Conference on Computer Vision*, pages 614–621. IEEE Computer Society.
- Ng, A. et Jordan, M. (2002). On discriminative vs. generative classifiers : A comparison of logistic regression and naive bayes. In *Neural Information Processing Systems*, volume 2, pages 841–848. Nips.
- Nguyen, M. et de la Torre, F. (2010). Optimal feature selection for support vector machines. *Pattern recognition*, 43(3) :584–591.
- Nowak, E., Jurie, F., et Triggs, B. (2006). Sampling strategies for bag-of-features image classification. *European Conference on Computer Vision*, pages 490–503.
- Opelt, A., Pinz, A., et Zisserman, A. (2006). A boundary-fragment-model for object detection. *European Conference on Computer Vision*, pages 575–588.
- Ormonet, D. et Sen, S. (2002). Kernel-based reinforcement learning. *Machine Learning*, 49(2–3) :161–178.
- Ozcanli, O., Tamrakar, A., Kimia, B., et Mundy, J. (2006). Augmenting shape with appearance in vehicle category recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 935–942. IEEE Computer Society.
- Ozuysal, M., Lepetit, V., et Fua, P. (2009). Pose estimation for category specific multiview object localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society.
- Paletta, L. et Pinz, A. (2000). Active object recognition by view integration and reinforcement learning. *Robotics and Autonomous Systems*, 31(1) :71–86.
- Paletta, L., Prantl, M., et Pinz, A. (2000). Learning temporal context in active object recognition using bayesian analysis. In *Proceedings of the IEEE 15th International Conference on Pattern Recognition*, volume 1, pages 695–699. IEEE Computer Society.
- Pan, S. J., Tsang, I. W., Kwok, J. T., et Yang, Q. (2009). Domain adaptation via transfer component analysis. In *Proceedings of the 21st International Joint conference on Artificial intelligence*, pages 1187–1192, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc.
- Pan, S. J. et Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10) :1345–1359.

- Peters, J. et Schaal, S. (2008). Reinforcement learning of motor skills with policy gradients. *Neural Network*, 21(4) :682–697.
- Petitjean, S. (1996). The enumerative geometry of projective algebraic surfaces and the complexity of aspect graphs. *International Journal of Computer Vision*, 19(3) :261–287.
- Ponce, J. (2006). *Toward category-level object recognition*, volume 4170. Springer-Verlag New York Inc.
- Porikli, F. (2005). Integral histogram : A fast way to extract histograms in cartesian spaces.
- Posner, M. et Keele, S. (1968). On the genesis of abstract ideas. *Journal of experimental psychology*, 77(3p1) :353.
- Powell, W. (2007). *Approximate Dynamic Programming : Solving the Curses of Dimensionality*. John Wiley & Sons, Inc. Hoboken, NJ, USA.
- Puterman, M. (1994). *Markov Decision Processes : Discrete Stochastic Dynamic Programming*. John Wiley & Sons, Inc. New York, NY, USA.
- Quattoni, A., Collins, M., et Darrell, T. (2008). Transfer learning for image classification with sparse prototype representations. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Quinlan, J. (1993). *C4.5 : programs for machine learning*. Morgan Kaufmann.
- Raina, R., Shen, Y., Ng, A., et McCallum, A. (2004). Classification with hybrid generative/discriminative models. *Advances in neural information processing systems*, 16 :545–552.
- Ramer, U. (1972). An iterative procedure for the polygonal approximation of plane curves. *Computer Graphics and Image Processing*, 1(3) :244–256. Elsevier.
- Rasmussen, C. E. et Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. Springer-Verlag, New York.
- Remagnino, P., Illingworth, J., Kittler, J., et Matas, J. (1995). Intentional control of camera look direction and viewpoint in an active vision system. *Image and Vision Computing*, 13(2) :79–88.
- Riedmiller, M., Gabel, T., Hafner, R., et Lange, S. (2009). Reinforcement learning for robot soccer. *Autonomous Robots*, 27(1) :55–73.
- Ripley, B. (2008). *Pattern recognition and neural networks*. Cambridge University Press.
- Rish, I. (2001). An empirical study of the naive bayes classifier. In *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, pages 41–46.
- Roberts, L. (1963). *Machine perception of three-dimensional solids*. PhD thesis, Massachusetts Institute of Technology, Lexington Lincoln Lab.
- Rohrbach, M., Stark, M., Szarvas, G., Gurevych, I., et Schiele, B. (2010). What helps where – and why? semantic relatedness for knowledge transfer. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society.
- Roobaert, D. et Van Hulle, M. (1999). View-based 3d object recognition with support vector machines. In *Proceedings of the IEEE Neural Networks for Signal Processing IX. Signal Processing Society Workshop*, pages 77–84. IEEE Computer Society.
- Rosch, E., Mervis, C., Gray, W., Johnson, D., et Boyes-Braem, P. (1976). Basic objects in natural categories. *Cognitive psychology*, 8(3) :382–439.
- Rosenblatt, F. (1958). The perceptron : A probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6) :386.
- Rothganger, F., Lazebnik, S., Schmid, C., et Ponce, J. (2006). 3d object modeling and recognition using local affine-invariant image descriptors and multi-view spatial constraints. *International Journal of Computer Vision*, 66(3) :231–259.
- Rothwell, C., Forsyth, D., Zisserman, A., et Mundy, J. (1993). Extracting projective structure from single perspective views of 3d point sets. In *Proceedings of the Fourth International Conference on Computer Vision*, pages 573–582. IEEE Computer Society.
- Roy, S. et Kulkarni, N. (2004). Active 3-d object recognition using appearance-based aspect graphs. In *Proceedings of the Indian Conference on Computer Vision, Graphics and Image Processing*, pages 40–45. Citeseer.

- Rutishauser, U., Walther, D., Koch, C., et Perona, P. (2004). Is bottom-up attention useful for object recognition ?
- Rybski, P., Huber, D., Morris, D., et Hoffman, R. (2010). Visual classification of coarse vehicle orientation using histogram of oriented gradients features. In *2010 IEEE Intelligent Vehicles Symposium*. IEEE Computer Society.
- Saenko, K., Kulis, B., Fritz, M., et Darrell, T. (2010). Adapting visual category models to new domains. *European Conference on Computer Vision*, pages 213–226.
- Sanderson, A. et Weiss, L. (1980). Image based visual servo control using relational graph error signal. In *Proceedings of the IEEE International Conference on Cybernetics and Society*, pages 1074–1077. IEEE Computer Society.
- Santner, T. J., Williams, B. J., et Notz, W. (2003). *The Design and Analysis of Computer Experiments*. Springer-Verlag, Berlin-Heidelberg.
- Sarojini, K. et Thangavel, K. (2010). Supervised feature subset selection using extended fuzzy absolute information measure for handling different discretized datasets. *Procedia Computer Science*, 2 :256–264.
- Sasena, M. J. (2002). *Flexibility and Efficiency Enhancements for Constrained Global Design Optimization with Kriging Approximations*. PhD thesis, University of Michigan, USA.
- Satpal, S. et Sarawagi, S. (2007). Domain adaptation of conditional probability models via feature subsetting. In *Proceedings of the 11th European conference on Principles and Practice of Knowledge Discovery in Databases*, pages 224–235, Berlin, Heidelberg. Springer-Verlag.
- Savarese, S. et Fei-Fei, L. (2007). 3d generic object categorization, localization and pose estimation.
- Savarese, S. et Fei-Fei, L. (2008). View synthesis for recognizing unseen poses of object classes. *European Conference on Computer Vision*, pages 602–615.
- Schapire, R., Freund, Y., Bartlett, P., et Lee, W. (1998). Boosting the margin : A new explanation for the effectiveness of voting methods. *The annals of statistics*, 26(5) :1651–1686.
- Schiele, B. et Crowley, J. (2002). Transinformation for active object recognition. In *Proceedings of the IEEE Sixth International Conference on Computer Vision*, pages 249–254. IEEE Computer Society.
- Schiele, B. et Crowley, J. L. (1996). Probabilistic object recognition using multidimensional receptive field histograms. In *Proceedings of the International conference on Pattern Recognition*, pages 610–619.
- Schmid, C., Bobet, P., Lamiroy, B., et Mohr, R. (1996). An image oriented cad approach. *Object Representation in Computer Vision*, 2 :221–245.
- Schmid, C. et Mohr, R. (1997). Local grayvalue invariants for image retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5) :530–535.
- Schmid, C., Mohr, R., et Bauckhage, C. (2000). Evaluation of interest point detectors. *International Journal of computer vision*, 37(2) :151–172.
- Schneiderman, H. et Kanade, T. (2000). A statistical method for 3d object detection applied to faces and cars. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, page 1746. IEEE Computer Society.
- Schölkopf, B. et Smola, A. (2002). *Learning with kernels : support vector machines, regularization, optimization, and beyond*. the MIT Press.
- Schonlau, M. (1997). *Computer Experiments and Global Optimization*. PhD thesis, University of Waterloo, Canada.
- Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, 6(2) :461–464.
- Scott, D. (1992). *Multivariate density estimation*, volume 139. Wiley Online Library.
- Seibert, M. et Waxman, A. (1992). Adaptive 3-d object recognition from multiple views. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2) :107–124.
- Shafer, G. (1976). *A mathematical theory of evidence*, volume 1. Princeton university press Princeton, NJ.
- Shapira, R. et Freeman, H. (1978). Computer description of bodies bounded by quadric surfaces from a set of imperfect projections. *IEEE Transactions on Computers*, 100(9) :841–854.

- Shimodaira, H. (2000). Improving predictive inference under covariate shift by weighting the log-likelihood function. *Journal of Statistical Planning and Inference*, 90(2) :227–244.
- Shotton, J., Blake, A., et Cipolla, R. (2005). Contour-based learning for object detection.
- Silla, C. et Freitas, A. (2011). A survey of hierarchical classification across different application domains. *Data Mining and Knowledge Discovery*, pages 1–42.
- Sim, R. (2000). Bayesian exploration for mobile robots. Technical report, Citeseer.
- Singh, S. S., Kantas, N., Vo, B., Doucet, A., et Evans, R. J. (2007). Simulation-based optimal sensor scheduling with application to observer trajectory planning. *Automatica*, 43(5) :817–830.
- Sipe, M. A. et Casasent, D. (2002). Feature space trajectory methods for active computer vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(12) :1634–1643.
- Smeulders, A. W., Worring, M., Santini, S., Gupta, A., et Jain, R. (2000). Content-based image retrieval at the end of the early years. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22 :1349–1380.
- Strens, M. J. A. (2000). A bayesian framework for reinforcement learning. In *Proceedings of the 17th International Conference on Machine Learning*, pages 943–950. ACM.
- Strobl, C., Boulesteix, A., Kneib, T., Augustin, T., et Zeileis, A. (2008). Conditional variable importance for random forests. *BMC bioinformatics*, 9(1) :307.
- Sun, M., Su, H., Savarese, S., et Fei-Fei, L. (2009). A multi-view probabilistic model for 3d object classes.
- Suna, Z., Bebisa, G., et Millerb, R. (2004). Object detection using feature subset selection. *Pattern Recognition*, 37 :2165–2176.
- Sutton, R. S. et Barto, A. G. (1998). *Reinforcement Learning : An Introduction*. The MIT press, Cambridge, USA.
- Swain, M. et Ballard, D. (1991). Color indexing. *International journal of computer vision*, 7(1) :11–32.
- Tan, T., Sullivan, G., et Baker, K. (1994). Fast vehicle localisation and recognition without line extraction and matching. In *Proceedings of the 5th British Machine Vision Conference*, pages 85–94. Manchester, U. K :[s. n].
- Tang, E., Suganthan, P., Yao, X., et Qin, A. (2005). Linear dimensionality reduction using relevance weighted lda. *Pattern recognition*, 38(4) :485–493.
- Tarabanis, K., Allen, P., et Tsai, R. (1995). A survey of sensor planning in computer vision. *IEEE Transactions on Robotics and Automation*, 11(1) :86–104.
- Tarantola, A. (1987). *Inverse problem theory*, volume 130. Elsevier Amsterdam etc.
- Tarr, M., Williams, P., Hayward, W., et Gauthier, I. (1998). Three-dimensional object recognition is viewpoint dependent. *Nature Neuroscience*, 1(4) :275–277.
- Tesauro, G. (1995). Temporal difference learning and td-gammon. *Communications of the ACM*, 38(3) :58–68.
- Tewari, A. et Bartlett, P.L. (2007). On the consistency of multiclass classification methods. *he Journal of Machine Learning Research*, volume 8, pages 1007–1025. JMLR. org
- Thiria, S., Lechevallier, Y., Gascuel, O., et Canu, S. (1997). *Statistique et méthodes neuronales*, volume 4. Dunod.
- Thomas, A., Ferrar, V., Leibe, B., Tuytelaars, T., Schiel, B., et Van Gool, L. (2006). Towards multi-view object class detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 2, pages 1589–1596. IEEE Computer Society.
- Thomas, A., Ferrari, V., Leibe, B., Tuytelaars, T., et Van Gool, L. (2009). Using multi-view recognition and meta-data annotation to guide a robot’s attention. *The International Journal of Robotics Research*, 28(8) :976.
- Thureson, J. et Carlsson, S. (2004). Appearance based qualitative image description for object class recognition. *European Conference on Computer Vision*, pages 518–529.
- Titsias, M. et Likas, A. (2001). Shared kernel models for class conditional density estimation. *IEEE Transactions on Neural Networks*, 12(5) :987–997.
- Tola, E., Lepetit, V., et Fua, P. (2008). A fast local descriptor for dense matching. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–8. IEEE Computer Society.

- Torkkola, K. (2003). Feature extraction by non parametric mutual information maximization. *The Journal of Machine Learning Research*, 3 :1415–1438.
- Torralba, A., Murphy, K., et Freeman, W. (2007). Sharing visual features for multiclass and multiview object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 854–869.
- Tousch, A., Herbin, S., et Audibert, J. (2008). Semantic lattices for multiple annotation of images. In *Proceeding of the 1st ACM International Conference on Multimedia Information Retrieval*, pages 342–349. ACM.
- Tsotsos, J. (1992). On the relative complexity of active vs. passive visual search. *International journal of computer vision*, 7(2) :127–141.
- Turing, A. (1950). Computing machinery and intelligence. *Mind*, 59(236) :433–460.
- Turk, M. et Pentland, A. (1991). Eigenfaces for recognition. *Journal of cognitive neuroscience*, 3(1) :71–86.
- Tuytelaars, T. et Van Gool, L. (1999). Content-based image retrieval based on local affinity invariant regions. In *Visual Information and Information Systems*, pages 656–656. Springer.
- Tuytelaars, T. et Van Gool, L. (2000). Wide baseline stereo matching based on local, affinity invariant regions. In *Proceedings of the British Machine Vision Conference*, pages 412–425. Manchester, U. K :[s. n].
- Ullman, S. et Epshtein, B. (2006). Visual classification by a hierarchy of extended fragments. *Toward category-level object recognition*, pages 321–344. Springer.
- Ullman, S., Vidal-Naquet, M., et Sali, E. (2002). Visual features of intermediate complexity and their use in classification. *nature neuroscience*, 5(7) :682–687.
- Ulusoy, I. et Bishop, C. (2006). Comparison of generative and discriminative techniques for object detection and classification. *Toward Category-Level Object Recognition*, pages 173–195. Springer.
- Vapnik, V. (2000). *The nature of statistical learning theory*. Springer Verlag.
- Varma, M. et Ray, D. (2007). Learning the discriminative power-invariance trade-off. *IEEE International Conference on Computer Vision*, 0 :1–8.
- Veltkamp, R. et Hagedoorn, M. (2001). State of the art in shape matching. *Principles of visual information retrieval*, page 87.
- Vembu, S. et Gärtner, T. (2010). Label ranking algorithms : A survey. *Preference Learning*, page 45.
- Villegas, M. et Paredes, R. (2010). Dimensionality reduction by minimizing nearest-neighbor classification error. *Pattern Recognition Letters*.
- Viola, P. et Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages I–511. IEEE Computer Society.
- Vural, V. et Dy, J. (2004). A hierarchical method for multi-class support vector machines. In *Proceedings of the twenty-first International Conference on Machine Learning*, page 105. ACM.
- Wang, C. et Mahadevan, S. (2008). Manifold alignment using procrustes analysis. In *Proceedings of the 25th International Conference on Machine Learning*, pages 1120–1127, New York, NY, USA. ACM.
- Wang, C. et Mahadevan, S. (2009). Manifold alignment without correspondence. In *Proceedings of the 21st International Joint Conference on Artificial Intelligence*, pages 1273–1278, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc.
- Watkins, C. et Dayan, P. (1992). Q-learning. *Machine Learning*, 8(3) :279–292.
- Weiss, I. (1992). Geometric invariants and object recognition. *International Journal of Computer Vision*, 10(3) :207–231.
- Weston, J. et Watkins, C. (1999). Support vector machines for multi-class pattern recognition. In *Proceedings of the seventh European symposium on artificial neural networks*, volume 4.
- Weyl, H. (1997). *The classical groups : their invariants and representations*. Princeton University Press.
- Whitehead, S. D. et Ballard, D. H. (1991). Learning to perceive and act by trial and error. *Machine Learning*, 7(1) :45–83.

- Winkeler, J., Manjunath, B., et Chandrasekaran, S. (1999). Subset selection for active object recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, page 2511. IEEE Computer Society.
- Winn, J., Criminisi, A., et Minka, T. (2005). Object categorization by learned universal visual dictionary.
- Worrall, A., Sullivan, G., et Baker, K. (1994). Pose refinement of active models using forces in 3d. *European Conference on Computer Vision*, pages 341–350.
- Wu, T., Lin, C., et Weng, R. (2004). Probability estimates for multi-class classification by pairwise coupling. *The Journal of Machine Learning Research*, 5 :975–1005.
- Xiao, J. et Shah, M. (2004). Automatic target recognition using multi-view morphing. *Proceedings of SPIE on Automatic Target Recognition*, 14 :391–399.
- Xiao, Z., Dellandrea, E., Dou, W., et Chen, L. (2007). Automatic hierarchical classification of emotional speech. *International Symposium on Multimedia Workshops*, pages 291–296.
- Xu, L., Krzyzak, A., et Suen, C. (1992). Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man and Cybernetics*, 22(3) :418–435.
- Ye, Y., Tsotsos, J., et of Toronto. Dept. of Computer Science, U. (1999). Sensor planning for 3d object search. *Computer Vision and Image Understanding*, 73(2) :145–168.
- Yilmaz, A., Javed, O., et Shah, M. (2006). Object tracking : A survey. *Acm Computing Surveys (CSUR)*, 38(4) :13.
- Yusta, S. (2009). Different metaheuristic strategies to solve the feature selection problem. *Pattern Recognition Letters*, 30(5) :525–534.
- Zegers, P. et Johnson, J. (2006). Consistent density function estimation with multilayer perceptrons. In *Proceedings of the IEEE International Joint Conference on Neural Networks*, pages 1128–1135. IEEE Computer Society.
- Zhang, H., Berg, A., Maire, M., et Malik, J. (2006). Svm-knn : Discriminative nearest neighbor classification for visual category recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 2, pages 2126–2136. IEEE Computer Society.
- Zhang, Z., Li, M., Huang, K., et Tan, T. (2008). Boosting local feature descriptors for automatic objects classification in traffic scene surveillance. In *Proceedings of the IEEE 19th International Conference on Pattern Recognition*, pages 1–4. IEEE Computer Society.
- Zhou, X. S., Comaniciu, D., et Krishnan, A. (2003). Conditional feature sensitivity : A unifying view on active recognition and feature selection. *Proceedings of the IEEE International Conference on Computer Vision*, 2 :1502.
- Zhu, J., Rosset, S., Zou, H., et Hastie, T. (2006). Multi-class adaboost. *Ann Arbor*, 1001 :48109.
- Zongker, D. et Jain, A. (1996). Algorithms for feature selection : An evaluation. In *Proceedings of the IEEE 13th International Conference on Pattern Recognition*, volume 2, pages 18–22. IEEE Computer Society.

NOTATIONS

ACP	Analyse en Composantes Principales
ADL	Analyse Discriminante Linéaire
AIC	<i>Akaike Information Criterion</i> (critère d'information d'Akaike)
AME	Adaptative Multi-Échelles
AUC	<i>Area Under Curve</i> (aire sous la courbe ROC)
BIC	<i>Bayesian Information Criterion</i> (critère d'information bayésien)
CAO	Conception assistée par ordinateur
cf.	confer
CMIM	<i>Conditional Mutual Information Maximization</i> (maximisation de l'information mutuelle conditionnelle)
CPDV	Conditions de Prise De Vue
CTF	<i>Coarse-To-Fine</i> (de grossier vers fin)
DPEGO	<i>Dynamic Programming with Efficient Global Optimization</i> (programmation dynamique avec optimisation globale efficiente)
EGO	<i>Efficient Global Optimization</i> (optimisation globale efficiente)
EM	Espérance-Maximisation
GAO	Graphe Acyclique Orienté
GPQL	<i>Gaussian Process with Q-Learning</i> (Q-learning avec processus gaussiens)
i.e.	
i.i.d.	Indépendamment et identiquement distribué
IM	Information Mutuelle
ISM	<i>Implicit Shape Model</i> (modèle de silhouette implicite)
LHS	<i>Latin Hypercube Sampling</i> (échantillonnage par hypercube latin)
MAP	Maximum A Posteriori
MIM	<i>Mutual Information Maximization</i> (maximisation de l'information mutuelle)
MRE	Minimisation du Risque Empirique
PG	Processus Gaussien
RMSE	<i>Root Mean Square Error</i> (erreur au sens des moindres carrés)
ROC	<i>Receiver Operating Characteristic</i>
SVM	<i>Support Vector Machine</i> (machine à vecteurs supports)
vs.	<i>versus</i>
a	action ($a \in \mathbb{A}$)
\mathbb{A}	espace des actions
\mathbf{A}	ensemble d'actions
\mathcal{A}	ensemble de données d'apprentissage
$Aire_T$	Aire sous la courbe de performance cumulée
α	coefficient de pondération ($\alpha \in [0, 1]$)
$\operatorname{argmax}(\cdot); \operatorname{argmin}(\cdot)$	argument maximisant (\cdot); argument minimisant (\cdot);

b	biais associé au SVM
$b[\cdot]$	vecteur binaire ($b[\cdot] \in \{0, 1\}$)
\mathbf{b}	vecteur de régression
β	coefficient de normalisation
$budget_{INTERP}$	budget d'échantillon pour l'interpolation
$budget_{OPT}$	budget d'échantillon pour l'optimisation
C	ensemble des méta-classes d'une taxonomie
C	paramètre de régularisation du SVM
\mathcal{C}	critère de planification adaptatif (ou max-adaptatif)
$\text{card}(\cdot)$	cardinal
$\text{Corr}(\cdot)$	fonction de corrélation
d	dimension finale du descripteur
D	variable aléatoire sur \mathcal{D} ($D \in \{0, 1\}$)
\mathcal{D}	domaine
δ	angle absolu d'un segment (avec l'abscisse du repère image)
$\Delta\delta$	angle relatif entre deux segments
Δ_{Aire_T}	différence d'aire sous les courbes de performance cumulée
$\det(\cdot)$	déterminant
$\dim(\cdot)$	dimension
e	$\approx 7,4$
$\mathcal{E}(\cdot)$	entropie
ϵ	paramètre de la politique ϵ -greedy ($\epsilon \in [0, 1]$)
η	distance entre les milieux de deux segments
\prec	opérateur <i>est-un</i>
\mathcal{F}	famille de fonctions
$f(\cdot)$	classifieur
$\mathbf{f}(\cdot)$	vecteur de régression (fonction des données)
Ford.	ensemble ordonné de réels
$g(\cdot, \cdot)$	fonction de mélange gaussien
γ	facteur d'oubli
H	horizon de planification
$\mathbf{1}_{\{condition\}}$	indicateur (égal à 1 si <i>condition</i> est vérifiée, 0 sinon)
I	nombre total d'itérations de l'apprentissage par boosting
ι	longueur d'un segment
\mathcal{K}	nombre de classes de la base de données
$k(\cdot, \cdot)$	produit scalaire (ou noyau reproduisant)
K	entier naturel positif
$K\text{-ppv}$	K plus proches voisins
L	nombre total d'épisodes

$\mathcal{L}(\cdot, \cdot)$	fonction de perte
λ	paramètre de régularisation
$L(\cdot)$	fonction de vraisemblance
$LL(\cdot)$	fonction de log-vraisemblance
M	nombre de modes du mélange gaussien
$m(\cdot)$	moyenne d'un processus gaussien
$\max(\cdot); \min(\cdot)$	maximum de (\cdot) ; minimum de (\cdot)
μ	vecteur des moyennes du mélange gaussien
N	nombre de données d'apprentissage
N_δ	nombre de quantification du paramètre δ
N_ι	nombre de quantification du paramètre ι
N_η	nombre de quantification du paramètre η
$\mathcal{N}(\cdot, \cdot)$	loi normale
N_{PAIRES}	nombre de paires de segments
N_{SEG}	nombre de segments
N_{QUANTIF}	niveau de complexité de quantification du descripteur
N_{SPATIAL}	niveau de complexité spatial du descripteur
ν	multiplicateurs de Lagrange (coefficients des vecteurs supports du SVM)
$\ \cdot\ $	norme
ω	variable aléatoire sur Ω
Ω	ensemble des classes de la base de données
$\Omega^{(\rho)}(P_{\min})$	cadre de discernement de cardinalité ρ et de paramètre P_{\min}
$P(\cdot); \mathbb{E}(\cdot)$	probabilité; espérance
$p(\cdot \cdot, \cdot)$	fonction de transition d'état associée au MDP
$P_{\max}; P_{\min}$	seuil de décision; seuil de filtrage ($\in [0, 1]$)
$\text{pen}(\cdot)$	fonction de pénalité
Perf_{\max}	performance cumulée maximale
$\mathcal{PG}(m(\cdot), k(\cdot, \cdot))$	processus gaussien de fonction moyenne $m(\cdot)$ et de fonction de corrélation $k(\cdot, \cdot)$
$\varphi(\cdot), \Psi(\cdot)$	fonctions de transformation des données
$\phi(\cdot)$	densité de probabilité de la loi $\mathcal{N}(0, 1)$
$\Phi(\cdot)$	fonction de distribution cumulée de la loi $\mathcal{N}(0, 1)$
π	$\approx 3,14$
$\Pi(\cdot)$	politique de planification
\propto	proportionnel à
$q(\cdot \cdot, \cdot, \cdot)$	fonction de distribution de la récompense associée au MDP
$Q(\cdot, \cdot)$	fonction de valeur d'une action à partir d'un état
$\mathcal{R}(\cdot)$	risque associé au classifieur
\mathbf{R}	ensemble de récompenses
$R(\cdot)$	récompense cumulée espérée d'une séquence d'actions
$r(\cdot, \cdot)$	récompense espérée d'une action
r	récompense élémentaire
$\rho; \varrho$	cardinal du cadre de discernement ($\in \mathbb{N}^*$); complémentaire de ρ à \mathcal{K}

s	état du MDP
$s(\cdot)$	fonction de score
\mathcal{S}	domaine source
S	espace d'états
σ^2	variance
Σ	matrice de covariance du mélange gaussien
$\text{sign}(\cdot)$	fonction de signe ($\in \{-1, 1\}$)
Σ	somme
t	pas de temps
T	budget d'observations pour la reconnaissance
\mathcal{T}	domaine cible
T_{moy}	moyenne (en nombre d'observations) de la courbe de performance cumulée
θ	paramètres d'un modèle et variable aléatoire associée à Θ
Θ	espace des paramètres des modèles
tol	tolérance de voisinage autour des CPDV visitées
v	modalité d'acquisition et variable aléatoire associée à \mathcal{V}
\mathcal{V}	espace des modalités d'acquisition
\mathbf{V}_t	ensemble des modalités d'acquisition d'une séquence de t observations
$V(\cdot)$	fonction de valeur d'un état
V_{inter}	variance inter-classes
V_{intra}	variance intra-classe
V_{term}	valeur de l'état terminal
w	poids associée à une donnée
x	observation et variable aléatoire associée à \mathcal{X}
\mathcal{X}	espace des données (ou espace de description)
\mathbf{X}_t	ensemble des données d'une séquence de t observations
ξ	paramètres de relaxation du SVM
y, Y	fonctions de transformation des données

COMMUNICATIONS SCIENTIFIQUES

REVUES AVEC COMITÉ DE LECTURE

Defretin, J., Marzat, J. and Piet-Lahanier, H. (2011). Model-free active reinforcement learning with Gaussian processes : an application to active recognition. *Soumis*.

CONFÉRENCES AVEC COMITÉ DE LECTURE

Defretin, J., Marzat, J. and Piet-Lahanier, H. (2010). Learning viewpoint planning in active recognition on a small sampling budget : a kriging approach. In *Proceedings of the IEEE International Conference on Machine Learning and Applications*, pages 169–174 , Washington D.C., USA. IEEE Computer Society.

Defretin, J., Herbin, S., Le Besnerais, G., and Vayatis, N. (2010). Adaptive planification in active 3d object recognition for many classes of objects. In *RSS Workshop : Toward Closing the Loop : Active Learning for Robotics*, Zaragoza, Spain.

Titre Stratégies de vision active pour la reconnaissance d'objets

Résumé Cette thèse, réalisée en coopération avec l'ONERA, concerne la reconnaissance active d'objets 3D par un agent autonome muni d'une caméra d'observation. Alors qu'en reconnaissance passive les modalités d'acquisition des observations sont imposées et génèrent parfois des ambiguïtés, la reconnaissance active exploite la possibilité de contrôler en ligne ces modalités d'acquisition au cours d'un processus d'inférence séquentiel dans le but de lever l'ambiguïté. L'objectif des travaux est d'établir des stratégies de planification dans l'acquisition de l'information avec le souci d'une mise en œuvre réaliste de la reconnaissance active. Le cadre de l'apprentissage statistique est pour cela mis à profit. La première partie des travaux se consacre à apprendre à planifier. Deux contraintes réalistes sont prises en compte : d'une part, une modélisation imparfaite des objets susceptible de générer des ambiguïtés supplémentaires ; d'autre part, le budget d'apprentissage est coûteux (en temps, en énergie), donc limité. La deuxième partie des travaux s'attache à exploiter au mieux les observations au cours de la reconnaissance. La possibilité d'une reconnaissance active multi-échelles est étudiée pour permettre une interprétation au plus tôt dans le processus séquentiel d'acquisition de l'information. Les observations sont également utilisées pour estimer la pose de l'objet de manière robuste afin d'assurer la cohérence entre les modalités planifiées et celles réellement atteintes par l'agent visuel.

Mots-clés vision active, reconnaissance d'objets, planification, apprentissage statistique, apprentissage actif, adaptation de domaine.

Title Active vision strategies for object recognition

Abstract This PhD thesis, conducted in cooperation with ONERA, focuses on active 3D object recognition by an autonomous visual agent. Whereas in passive recognition, acquisition modalities of observations are fixed and may generate ambiguities, active recognition exploits the possibility of controlling these modalities online in a sequential inference process in order to remove these ambiguities. The aim of this work is to design, in a statistical learning framework, planning strategies in the acquisition of information while achieving a realistic implementation of active recognition. The first part of the work is dedicated to learning to plan. Two realistic constraints are taken into account : on the one hand, planning with imperfect object modeling may generate further ambiguities ; on the other hand, the learning cost (in time, energy) is expensive and therefore limited. The second part of this work focuses on maximally exploiting observations acquired during recognition. The possibility of an active multi-scale recognition is investigated to allow an interpretation as soon as the sequential acquisition process begins. Observations are also used to robustly estimate the pose of the object to ensure consistency between the planned and actual modality of the visual agent.

Keywords active vision, pattern recognition, planning, machine learning, active learning, domain adaptation.