



**HAL**  
open science

# Traitement possibiliste d'images, application au recalage d'images

Wissal Ben Marzouka

► **To cite this version:**

Wissal Ben Marzouka. Traitement possibiliste d'images, application au recalage d'images. Traitement du signal et de l'image [eess.SP]. Ecole nationale supérieure Mines-Télécom Atlantique, 2022. Français. NNT : 2022IMTA0271 . tel-03917545

**HAL Id: tel-03917545**

**<https://theses.hal.science/tel-03917545>**

Submitted on 2 Jan 2023

**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.

# THESE DE DOCTORAT DE

L'ÉCOLE NATIONALE SUPERIEURE MINES-TELECOM ATLANTIQUE  
BRETAGNE PAYS DE LA LOIRE - IMT ATLANTIQUE

ÉCOLE DOCTORALE N° 601  
*Mathématiques et Sciences et Technologies  
de l'Information et de la Communication*  
Spécialité : *Signal, image, vision*

Par

**Wissal BEN MARZOUKA**

**Traitement possibiliste d'images, application au recalage d'images**

Thèse présentée et soutenue à l'IMT Atlantique Brest, le 28/06/2022

Unité de recherche : Latim (IMT Atlantique – France) et LIPAH (FST Manar – Tunisie)

Thèse N° : 2022IMTA0271

## Rapporteurs avant soutenance :

Imed Riadh FARAH      Professeur, ISAMM Manouba (Tunisie)  
El-Hadi ZAHZAH      Maître de conférences (HDR), Université de La Rochelle (France)

## Composition du Jury :

Président :      Ali KHENCHAF      Professeur, ENSTA Bretagne (France)  
Examineurs :    Imed Riadh FARAH      Professeur, ISAMM Manouba (Tunisie)  
                         El-Hadi ZAHZAH      Maître de conférences (HDR), Université de La Rochelle (France)  
                         Najoua ESSOUKRI BEN AMARA      Professeur, ENIS Sousse (Tunisie)

Dir. de thèse :    Basel SOLAIMAN      Professeur, IMT Atlantique, Brest (France)  
Co-dir. de thèse : Khaled BSAIES      Professeur, FST MANAR (Tunisie)

## Invité(s)

Atef HAMMOUDA      Maître de conférences (HDR), FST MANAR (Tunisie)  
Zouhour BEN DHIAF      Maître assistante, FST MANAR (Tunisie)



# Dédicaces

Toutes les lettres ne sauraient trouver les mots qu'il faut... 

Tous les mots ne sauraient exprimer la gratitude, l'amour, la reconnaissance... 

C'est tout simplement que... 

## *Je dédies cette thèse*

A la mémoire de mon référent indéfectible, **Mon père Tahar BEN MARZOUKA**,  
A la source de la tendresse et de la sureté, **Ma mère Sarra BOUZIDI**,  
A ma source de bonheur et tranquillité, **A mes grands parents**,  
Aux beaux yeux de ma chère, Ma sœur **Wiem BEN MARZOUKA**,  
A mon adorable fille, Ma sœur **Wided BEN MARZOUKA**,  
A ma source de confiance, Mon cher frère **Mohamed BEN MARZOUKA**,  
A mon chère supporteur, Mon frère **Ramzi**,  
A ma perle **Maryouma**,  
A mes chères sœurs **Nouhé, Soumaya, Tasnime & Rima**,  
A mes chères tentes, **Sonia, Najet et Affifa**,  
A mes chères oncles, maternel et paternel spécialement  
A **Tonton Abderrazek, Lotfi, Wahbi, Raouf, Abderrahmen, Raouf**,  
A chaque membre de **mes chères familles, BEN MARZOUKA & BOUZIDI**,  
A ma princesse Chouchi, Ma belle **chiraz & ma adorable Tata Amel**,  
A la plus généreuse famille, **Famille Mamah**,  
A mon cher confiant **Anass**,  
A mes chères compagnonnes pleines de souvenirs, **Hana, Fatma et Asma**,  
A mes chère semblables **Hajoura, Imou, Amouna**,  
A mes chers amis, **Maher, Atef, Jamila, Mohamed, Bassem, Aymen, Ramzi**,  
A mes chers tuteurs paternels, **Mr. Atef & Mr. Basel**, A ma chère **Tata sawsan**,  
A ma coquette adorable **Zouhour**,  
A ma **TUNISIE**,  
A toute personne qui m'a fait confiance,  
Ce modeste travail est le fruit de vos encouragements et votre confiance...,  
Je voulais juste vous dire... **UN GRAND MERCI**.



**Wissal BEN MARZOUKA** 

# Remerciements

C'est l'occasion ou jamais pour adresser mes vifs et sincères remerciements à tous ceux qui de près ou de loin ont contribué à l'élaboration de ce travail, particulièrement :

Je tiens à remercier mon cher directeur de thèse **Mr. Basel SOLAIMAN**, professeur à l'IMT Atlantique, pour ses critiques, ses conseils et ses encouragements. J'ai été très honoré de suivre ses recommandations et de travailler sous sa tutelle. Je vous remercie de tout mon cœur et je vous promet que je vais continuer mon parcours en suivant vos conseils, et en me basant sur les axes solides que vous m'avez appris.

Je voudrais également exprimer mes profonds remerciements à **Mr. Atef HAMMOUDA** mon cher Co-encadrant, maître de conférence (HDR) qui m'a initié à la recherche, qui a su grâce à sa science immense, m'orienter dans la bonne voie, qui avec sa générosité et sa patience, a guidé mes pas dans la recherche en didactique des langues, qui a su m'obliger à aller toujours plus en avant, et m'a prodigué les conseils judicieux qui m'aident à mener à bien cette recherche. Qu'il trouve, dans l'aboutissement de ce travail, l'expression de l'infinie reconnaissance de son étudiante respectueuse et fidèle.

J'adresse aussi mes remerciements à mon cher directeur de thèse **Mr. Khaled BSAIS**, professeur à la FST, pour l'opportunité qu'il m'a accordée en acceptant de diriger ce travail et pour ses conseils.

Je remercie vivement **Madame Zouhour BEN DHIEF** ma cher co-encadrante qui m'a fait profiter de son vaste savoir dans le domaine ainsi que de son expérience ; elle a été plus qu'une sœur pour moi.

Mes directeurs ainsi que mes co-encadrants font bien plus que simplement m'encadrer. Vous m'avez beaucoup supporté tout au long de ce travail. Je tiens à exprimer mes profondes reconnaissances pour vos qualités sur le plan académique et humain. Je Vous remercie également pour ce que vous m'avez apporté sur le plan scientifique, pour la qualité de vos conseils, pour toutes les heures passées à la relecture attentive de mes différentes productions écrites, pour votre disponibilité et votre bonne humeur.

Vous étiez disponibles, à l'écoute de mes nombreuses questions, et vous étiez toujours intéressés à l'avancée de mes travaux. Les nombreuses discussions que nous avons eu ainsi que vos conseils sont la source de la confiance que j'ai eu pour réussir ce travail. vos capacités d'analyse et vos enthousiasmes m'ont montré que le monde de la recherche pouvait être un univers passionnant. Enfin, vos nombreuses relectures et corrections de cette thèse ont été très appréciables. Cette thèse vous doit beaucoup. **Pour tout cela un GRAND MERCI.**

J'exprime ma gratitude et mes reconnaissances à madame Delphine LUCAS la responsable administrative à l'IMT Atlantique, pour ses efforts et votre contribution pour le bon déroulement des démarches administratives de ma thèse.

Enfin, je remercie les membres du jury pour l'honneur qu'ils m'ont fait en acceptant de juger mon travail.

Qu'ils trouvent ici l'expression de toute ma considération et mon respect.

# Table des matières

<b>Introduction générale</b>	<b>1</b>
<b>1 ÉTAT DE L'ART</b>	<b>4</b>
1.1 Introduction . . . . .	5
1.2 Systèmes d'acquisition des images . . . . .	5
1.3 Représentation de l'information d'une image . . . . .	6
1.3.1 Analyse à l'échelle du pixel . . . . .	7
1.3.2 Analyse de contours . . . . .	7
1.3.3 Analyse de régions . . . . .	8
1.4 Recalage d'images . . . . .	8
1.4.1 Définition et terminologie . . . . .	9
1.4.2 Paramètres et champ de déformation . . . . .	11
1.5 Familles d'approches du recalage . . . . .	12
1.5.1 Approche géométrique . . . . .	12
1.5.1.1 Présentation de l'approche géométrique . . . . .	13
1.5.1.2 Avantages de l'approche géométrique . . . . .	14
1.5.1.3 Limites de l'approche géométrique . . . . .	15
1.5.2 Approche iconique . . . . .	15
1.5.2.1 Présentation de l'approche iconique . . . . .	15
1.5.2.2 Avantage de l'approche iconique . . . . .	16
1.5.2.3 Limites de approche iconique . . . . .	16
1.5.3 Approche hybride . . . . .	16
1.6 Les critères de similarité . . . . .	16
1.6.1 Critère de similarité : Approches Géométriques . . . . .	17
1.6.2 Critère de similarité robuste . . . . .	17
1.6.2.1 Norme Euclidienne pour 2 points . . . . .	18
1.6.2.2 Algorithme ICP (Iterative Closest Point) . . . . .	18
1.6.2.3 Moyenne du carré de la distance . . . . .	18
1.6.2.4 Les cartes de distances . . . . .	18
1.6.2.5 Distance de Hausdorff . . . . .	18
1.6.3 Critère de similarité : Approches iconiques . . . . .	19
1.6.3.1 Identité . . . . .	19
1.6.3.2 Affine . . . . .	19
1.6.3.3 Fonctionnelle . . . . .	19
1.6.3.4 Dépendance . . . . .	20
1.7 Type de transformation . . . . .	20
1.7.1 Approche paramétrique . . . . .	20
1.7.1.1 Transformation globale . . . . .	20
1.7.1.2 Transformation semi-locale . . . . .	21

1.7.1.3	Régularisation . . . . .	21
1.7.2	Approches non-paramétriques . . . . .	22
1.7.2.1	Modèles élastiques . . . . .	22
1.7.2.2	Modèles fluides . . . . .	22
1.7.2.3	Modèles de flux optique . . . . .	22
1.7.2.4	Modèle de diffusion . . . . .	22
1.8	Optimisation . . . . .	23
1.8.1	Méthodes directes . . . . .	23
1.8.2	Méthodes exhaustives . . . . .	23
1.8.3	Méthodes numériques itératives . . . . .	23
1.8.4	Méthodes stochastiques . . . . .	23
1.9	Conclusion . . . . .	24
<b>2</b>	<b>RECALAGE D'IMAGES : APPROCHE GÉOMÉTRIQUE</b>	<b>25</b>
2.1	Introduction . . . . .	25
2.2	Recalage géométrique . . . . .	26
2.2.1	Techniques de recalage . . . . .	26
2.2.2	Classification selon la modalité . . . . .	27
2.2.3	Classification selon les primitives . . . . .	28
2.2.4	Classification selon le critère de similarité . . . . .	30
2.2.5	Processus du système du recalage géométrique . . . . .	30
2.3	Phases de recalage . . . . .	31
2.3.1	Apport du recalage géométrique . . . . .	31
2.3.2	Facteurs d'un système de recalage . . . . .	32
2.3.2.1	Extraction des primitives . . . . .	32
2.3.2.2	Extraction des points d'intérêts . . . . .	32
2.3.2.3	Extraction des contours . . . . .	33
2.3.2.4	Extraction des régions . . . . .	33
2.4	Méthodes de recalage géométrique . . . . .	34
2.4.1	Méthode SIFT (Scale-Invariant Feature Transform) . . . . .	34
2.4.2	Méthode SURF (Speed Up Robust Feature) . . . . .	35
2.4.3	Méthode BRIEF (Binary Robust Independent Elementary Features) . . . . .	35
2.4.4	Méthode ORB (Rotated BRIEF) . . . . .	35
2.4.5	Méthode BRISK (Binary Robust Invariant Scalable Keypoints) . . . . .	36
2.4.6	Méthode FREAK (Fast Retina Keypoint) . . . . .	36
2.4.7	Méthode Corner . . . . .	37
2.4.8	Méthode KAZE . . . . .	37
2.4.9	Méthode AKAZE (Accelerated KAZE Features) . . . . .	37
2.5	Évaluation des méthodes de recalage géométrique . . . . .	37
2.6	Conclusion . . . . .	39

<b>3 ESTIMATION DES DISTRIBUTIONS DES POSSIBILITES POUR LE RE-</b>	
<b>CALAGE GEOMETRIQUE</b>	<b>40</b>
3.1 Introduction . . . . .	41
3.2 Fondements de base . . . . .	42
3.3 Caractéristiques de l'information . . . . .	42
3.3.1 Donnée, information et connaissance . . . . .	42
3.3.2 Sources d'information . . . . .	42
3.3.2.1 Représentations des informations . . . . .	43
3.3.3 Qualité de l'information . . . . .	44
3.4 Imperfections de l'information . . . . .	45
3.5 Représentations numériques de connaissances imparfaites . . . . .	46
3.5.1 La théorie des probabilités . . . . .	47
3.5.2 La théorie de l'évidence ou de croyance . . . . .	47
3.5.3 La théorie des ensembles flous . . . . .	47
3.5.4 La théorie des possibilités . . . . .	47
3.6 Fondements de la théorie des possibilités . . . . .	48
3.6.1 Principe de base . . . . .	48
3.6.2 Concepts de base de la théorie des sous-ensembles flous . . . . .	48
3.6.2.1 Définition de la théorie des sous-ensembles flous . . . . .	48
3.6.2.2 Caractéristiques d'un sous-ensemble flou . . . . .	49
3.6.2.3 Éléments de base de la théorie des possibilités . . . . .	49
3.6.2.4 Fondement mathématique de la théorie des possibilités . . . . .	51
3.7 Approche de recalage basée sur une projection sémantique . . . . .	52
3.8 Projection sémantique supervisée . . . . .	54
3.8.1 Présentation . . . . .	54
3.8.2 Méthodes de classification supervisée existantes . . . . .	55
3.8.2.1 Les approches discriminantes . . . . .	55
3.8.2.2 Les approches génératives . . . . .	56
3.8.3 Études comparatives des méthodes existantes . . . . .	57
3.8.4 Méthode proposée . . . . .	57
3.9 Projection sémantique non supervisée . . . . .	58
3.9.1 Méthodes de clustering existantes . . . . .	59
3.9.1.1 Classification hiérarchique . . . . .	59
3.9.1.2 Classification par regroupement . . . . .	59
3.9.1.3 Méthode de classification C-Moyennes-Floues (FCM) . . . . .	60
3.9.1.4 Clustering multi-centroïdes basé sur le FCM . . . . .	61
3.9.2 Méthode proposée . . . . .	61
3.10 Génération des cartes de possibilité . . . . .	61
3.10.1 Contexte supervisé . . . . .	62
3.10.1.1 Apprentissage . . . . .	62
3.10.1.2 Modélisation de l'approche . . . . .	62
3.10.1.3 Calcul des distributions de possibilités . . . . .	62

3.10.2	Contexte non supervisé . . . . .	63
3.10.2.1	Indice de validité de clustering flou . . . . .	64
3.10.2.2	Phase de l'estimation . . . . .	66
3.10.2.3	Méthode pour l'estimation de la fonction de masse . . . . .	66
3.10.2.4	Estimation de la distribution de masse . . . . .	67
3.11	Conclusion . . . . .	68
<b>4</b>	<b>SYSTEME DE RECALAGE POSSIBILISTE</b>	<b>69</b>
4.1	Introduction . . . . .	69
4.2	Sources de connaissance pour le système de recalage . . . . .	70
4.2.1	Connaissance du niveau pixelique . . . . .	71
4.2.2	Connaissances du niveau sémantique . . . . .	74
4.3	Description des classes sémantiques . . . . .	76
4.4	Fusion de connaissances . . . . .	77
4.4.1	Principe . . . . .	78
4.4.2	Estimation des distributions de possibilités . . . . .	79
4.4.3	Fonctions de masse pour la fusion des connaissances . . . . .	81
4.5	Processus du recalage géométrique possibiliste proposé . . . . .	82
4.5.1	Extraction des primitives . . . . .	83
4.5.2	État de l'art sur les méthodes d'extraction des primitives . . . . .	84
4.5.3	Choix de la méthode d'extraction des primitives . . . . .	86
4.5.4	Mise en correspondance des primitives . . . . .	87
4.6	Estimation du modèle de transformation . . . . .	88
4.7	Le ré-échantillonnage et interpolation de l'image cible . . . . .	89
4.8	Conclusion . . . . .	89
<b>5</b>	<b>Expérimentation et évaluation du système de recalage possibiliste</b>	<b>90</b>
5.1	Introduction . . . . .	90
5.2	Application sur des images médicales : <u>Contexte supervisé</u> . . . . .	91
5.3	Présentation de la méthode BRISK . . . . .	91
5.3.1	Détection des primitives Scale-Space . . . . .	92
5.3.2	Description des primitives . . . . .	92
5.3.3	Phase de mise en correspondance des primitives . . . . .	93
5.3.4	Avantages et limites de la méthode BRISK . . . . .	94
5.3.5	Phase d'expérimentation . . . . .	95
5.3.6	Résultats d'expérimentation . . . . .	95
5.3.7	Interprétation, comparaison et évaluation . . . . .	97
5.4	Application sur des images satellites : <u>Contexte supervisé</u> . . . . .	98
5.4.1	Présentation des résultats . . . . .	99
5.4.1.1	Résultats d'expérimentations : Une seule transformation . . . . .	101
5.4.1.2	Résultats d'expérimentations : <i>Combinaison de transformations</i> . . . . .	108
5.4.2	Interprétation, comparaison et évaluation . . . . .	111
5.5	Application sur des images médicales : <u>Contexte non supervisé</u> . . . . .	112

---

5.5.1	Présentation de l'approche . . . . .	112
5.5.2	Plan d'expérimentation . . . . .	113
5.5.3	Expérimentations et résultats du recalage d'images possibiliste non supervisé	114
5.5.4	Interprétation, comparaison et évaluation . . . . .	117
5.6	Conclusion . . . . .	117
<b>Conclusions et perspectives</b>		<b>117</b>
<b>Bibliographie</b>		<b>120</b>

# Table des figures

1.1	Comparaison d'images avant (a) et après recalage (b) . . . . .	9
1.2	Principe général du recalage de deux images : Processus de recherche $T'$ . . . . .	10
1.3	Approches de recalage . . . . .	12
2.1	Images mono-modale, Imagerie médicale (Scanner) . . . . .	28
2.2	Images monomodale, Imagerie spatiale (Satellite) . . . . .	28
2.3	Images multimodal (IRM (2D) / CT (2D)) . . . . .	29
2.4	Schématisation d'un problème de recalage ; Comment retrouver les mouvements des points $A, B, C, D, E$ . . . . .	29
2.5	Détermination de l'angle de recalage de l'algorithme SURF, en analysant la répartition des réponses des ondelettes de Haar [Bay <i>et al.</i> , 2006] . . . . .	35
2.6	Principe de l'approche [Mikolajczyk et Schmid, 2005] . . . . .	36
3.1	Affectation des informations à l'ensemble des hypothèses . . . . .	44
3.2	Caractéristiques d'un sous-ensemble flou . . . . .	49
3.3	Génération des cartes possibilistes . . . . .	53
3.4	Schéma global de la classification supervisée . . . . .	54
3.5	Étapes de l'algorithme de clustering multi-centroïdes [Haouas <i>et al.</i> , 2019] . . . . .	66
3.6	Schéma global du passage pixel-centroïde-appartenance [Haouas <i>et al.</i> , 2019] . . . . .	67
4.1	Méthode de segmentation d'image par diffusion des connaissances possibilistes . . . . .	75
4.2	Modélisation du processus de classification possibiliste . . . . .	77
4.3	Base de connaissances semi-sémantique : Fusion des connaissances des niveaux pixelique et sémantique . . . . .	78
4.4	Extension de l'espace de représentation . . . . .	79
4.5	Approche proposée pour la génération des cartes possibilistes . . . . .	80
4.6	Processus d'estimation des distributions de possibilités . . . . .	81
4.7	Processus de projection des connaissance possibilistes . . . . .	82
4.8	Schéma global de l'approche de recalage possibiliste proposée . . . . .	83
5.1	Processus de recalage géométrique : Méthode BRISK . . . . .	92
5.2	Détection des points d'intérêt de l'espace d'échelle [Liu <i>et al.</i> , 2018] . . . . .	93
5.3	Description de points d'intérêt dans l'espace d'échelle [Liu <i>et al.</i> , 2018] . . . . .	93
5.4	Exemple d'une image IRM d'un cerveau d'un patient . . . . .	95
5.5	Image source du cerveau, (a), et l'image transformée de l'image source, (b), FT : Rotation . . . . .	96
	(a) Image source $Im_s$ . . . . .	96
	(b) Image transformée $Im_t$ . . . . .	96
	(a) Coupe IRM $Im_s$ . . . . .	96
	(b) Coupe IRM $Im_t$ . . . . .	96

5.5	Estimation des distributions de possibilités résultant des domaines d'apprentissage des experts (a) Image source, $Image_s$ , (b) Image cible, $Image_t$ , (c) Distribution de possibilité $Image_s$ , (d) Distribution de possibilité de $Image_t$ . . . . .	97
	(c) Projection possibiliste de $Im_s$ . . . . .	97
	(d) Projection possibiliste de $Im_t$ . . . . .	97
5.6	Évaluation du temps de traitement des résultats du BRISK par rapport à l'approche proposée (Image du cerveau) . . . . .	97
	(a) FT : Rotation . . . . .	97
	(b) FT : Translation . . . . .	97
5.7	Images de l'étude expérimentale . . . . .	99
5.8	Exemples d'images de la base d'images Quick Bird construite . . . . .	99
5.9	Protocole d'expérimentation . . . . .	100
5.10	Applications de transformation . . . . .	100
	(a) Image source Quickbird image . . . . .	100
	(b) Image cible Quickbird image . . . . .	100
5.11	Distributions de possibilités estimées résultant des domaines d'apprentissage . . . . .	101
	(a) Image source, $Im_s$ . . . . .	101
	(b) Image cible, $Im_t$ . . . . .	101
	(c) Distribution de possibilité de $Im_s$ . . . . .	101
	(d) Distribution de possibilité de $Im_t$ . . . . .	101
5.12	Cartes possibilistes résultantes des images source et cible . . . . .	102
5.13	Résultats de comparaisons du temps de calcul des méthodes au niveaux GL vs $\pi$ ; méthodes : ORB,BRISK,SURF et BRIEF ; Base d'images QuickBird . . . . .	104
	(a) Fonction de transformation : Rotation . . . . .	104
	(b) Fonction de transformation : Translation . . . . .	104
	(c) Bruit gaussien . . . . .	104
5.14	Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs $\pi$ , méthode ORB . . . . .	105
	(a) F.A de GL vs $\pi$ , Rotation . . . . .	105
	(b) F.A de GL vs $\pi$ , Translation . . . . .	105
	(c) F.A de GL vs $\pi$ , Bruit gaussien . . . . .	105
5.15	Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs $\pi$ , méthode SURF . . . . .	105
	(a) F.A de GL vs $\pi$ , Rotation . . . . .	105
	(b) F.A de GL vs $\pi$ , Translation . . . . .	105
	(c) F.A de GL vs $\pi$ , Bruit gaussien . . . . .	105
5.16	Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs $\pi$ , méthode BRISK . . . . .	105
	(a) F.A de GL vs $\pi$ , Rotation . . . . .	105
	(b) F.A de GL vs $\pi$ , Translation . . . . .	105
	(c) F.A de GL vs $\pi$ , Bruit gaussien . . . . .	105

5.17	Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs $\pi$ , méthode BRIEF . . . . .	106
	(a) F.A de GL vs $\pi$ , Rotation . . . . .	106
	(b) F.A de GL vs $\pi$ , Translation . . . . .	106
	(c) F.A de GL vs $\pi$ , Bruit gaussien . . . . .	106
	(a) Fonction de transformation : Rotation . . . . .	106
5.17	Résultats de comparaisons des valeurs d'erreurs de précision des méthodes au niveaux GL vs $\pi$ ; méthodes : ORB, BRISK, SURF et BRIEF . . . . .	107
	(b) Fonction de transformation : Translation . . . . .	107
	(c) Bruit gaussien . . . . .	107
5.18	Résultats de la comparaison du nombre de faux amers des méthodes $SURF_{GL}$ vs $SURF_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit . . . . .	108
	(a) <b>SURF</b> : GL, <b>FT</b> : <b>Rotation</b> . . . . .	108
	(b) <b>SURF</b> : $\pi$ , <b>FT</b> : <b>Rotation</b> . . . . .	108
	(c) <b>SURF</b> : GL, <b>FT</b> : <b>Translation</b> . . . . .	108
	(d) <b>SURF</b> : $\pi$ , <b>FT</b> : <b>Translation</b> . . . . .	108
	(a) <b>BRISK</b> : GL, <b>FT</b> : <b>Rotation</b> . . . . .	108
	(b) <b>BRISK</b> : $\pi$ , <b>FT</b> : <b>Rotation</b> . . . . .	108
5.18	Résultats de la comparaison du nombre de faux amers des méthodes $BRISK_{GL}$ vs $BRISK_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit . . . . .	109
	(c) <b>BRISK</b> : GL, <b>FT</b> : <b>Translation</b> . . . . .	109
	(d) <b>BRISK</b> : $\pi$ , <b>FT</b> : <b>Translation</b> . . . . .	109
5.19	Résultats de la comparaison du nombre de faux amers des méthodes $ORB_{GL}$ vs $ORB_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit . . . . .	109
	(a) <b>ORB</b> : GL, <b>FT</b> : <b>Rotation</b> . . . . .	109
	(b) <b>ORB</b> : $\pi$ , <b>FT</b> : <b>Rotation</b> . . . . .	109
	(c) <b>ORB</b> : GL, <b>FT</b> : <b>Translation</b> . . . . .	109
	(d) <b>ORB</b> : $\pi$ , <b>FT</b> : <b>Translation</b> . . . . .	109
5.20	Résultats de la comparaison du nombre de faux amers des méthodes $BRIEF_{GL}$ vs $BRIEF_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit . . . . .	110
	(a) <b>BRIEF</b> : GL, <b>FT</b> : <b>Rotation</b> . . . . .	110
	(b) <b>BRIEF</b> : $\pi$ , <b>FT</b> : <b>Rotation</b> . . . . .	110
	(c) <b>BRIEF</b> : GL, <b>FT</b> : <b>Translation</b> . . . . .	110
	(d) <b>BRIEF</b> : $\pi$ , <b>FT</b> : <b>Translation</b> . . . . .	110
5.21	Modélisation 3D des résultats de la comparaison des valeurs de précision de $SURF_{GL}$ vs $SURF_{\pi}$ ; FT : Rotation + Ajout du bruit . . . . .	111
	(a) <b>SURF</b> au niveau pixelique (GL); <b>FT</b> : <b>Rotation</b> . . . . .	111
	(b) <b>SURF</b> au niveau sémantique ( $\pi$ ); <b>FT</b> : <b>Rotation</b> . . . . .	111
5.22	Modélisation 3D des résultats de la comparaison des valeurs de précision de $ORB_{GL}$ vs $ORB_{\pi}$ ; FT : Rotation + Ajout du bruit . . . . .	111
	(a) <b>ORB</b> au niveau pixelique (GL); <b>FT</b> : <b>Rotation</b> . . . . .	111
	(b) <b>ORB</b> au niveau sémantique ( $\pi$ ); <b>FT</b> : <b>Rotation</b> . . . . .	111

5.23 Schéma global de l'approche non supervisée proposée pour le recalage des images possibilistes . . . . .	113
5.24 Protocole d'évaluation . . . . .	114
5.25 Image de la tumeur mammaire . . . . .	114
5.26 Exemple de la phase de projection possibiliste d'une coupe d'image IRM (Image source); (b) : Carte possibiliste $C_1$ , (c) : Carte possibiliste $C_2$ . . . . .	114
5.27 Exemple de la phase de projection possibiliste d'une coupe d'image IRM (Image transformée); (b) : Carte possibiliste $C_1$ , (c) : Carte possibiliste $C_2$ . . . . .	115
5.28 Évaluation du temps de calcul (TC (s)) de $SURF_{GL}$ vs $SURF_{\pi}$ . . . . .	115
(a) TC de SURF, GL vs $\pi$ , Rotation . . . . .	115
(b) TC de SURF, GL vs $\pi$ , Echelle . . . . .	115
(c) TC de SURF, GL vs $\pi$ , Bruit gaussien . . . . .	115
5.29 Évaluation du temps de calcul (TC (s)) de $BRISK_{GL}$ vs $BRISK_{\pi}$ . . . . .	115
(a) TC de BRISK, GL vs $\pi$ , Rotation . . . . .	115
(b) TC de BRISK, GL vs $\pi$ , Echelle . . . . .	115
(c) TC de BRISK, GL vs $\pi$ , Bruit gaussien . . . . .	115
5.30 Évaluation du temps de calcul (TC (s)) de $ORB_{GL}$ vs $ORB_{\pi}$ . . . . .	115
(a) TC de ORB, GL vs $\pi$ , Rotation . . . . .	115
(b) TC de ORB, GL vs $\pi$ , Echelle . . . . .	115
(c) TC de ORB, GL vs $\pi$ , Bruit gaussien . . . . .	115
5.31 Évaluation du nombre de faux amers (FA (%)) des méthodes de recalage selon l'espace de représentation des connaissances GL vs $\pi$ , méthodes : SURF, BRISK et ORB; FT : Rotation, Échelle et Bruit . . . . .	116

# Liste des tableaux

2.1	Présentation des méthodes de recalage de l'approche géométrique . . . . .	38
3.1	Attributs de la qualité de l'information . . . . .	45
3.2	Étude comparative des méthodes de classification supervisée . . . . .	57
4.1	Attributs de la qualité de l'information . . . . .	85
5.1	Avantages et limites de la méthode BRISK [Marzouka <i>et al.</i> , 2020a] . . . . .	94
5.2	Résultats d'expérimentation . . . . .	95
5.3	Tableau comparatif des résultats d'évaluation de BRISK et PBRISK . . . . .	98
5.4	Résultats de la comparaison des performances en utilisant algorithmes SURF, BRIEF, BRISK et ORB, niveaux de représentation des connaissances $GL$ vs $\pi$ .	102

# Liste des symboles et des abréviations

- **AGAST** : Adaptive and Generic Accelerated Segment Test
- **ANN** : Réseaux de neurones artificiels
- **BC** : Base de connaissances
- **BRIEF** : Binary Robust Independent Elementary Features
- **BRISK** : Binary Robust Invariant Scalable Keypoints
- **CBR** : Raisonnement à base de cas
- **CNB** : Classification naïve de Bayes
- **CVI** : indices de validations de clustering
- **DDL** : Degrés De Liberté
- **EM** : Espérance Maximisation
- **FA** : Nombre de faux amers
- **FAST** : Features from Accelerated Segment Test
- **FCM** : classification C-Moyennes-Floues
- **FCM multi-centroïdes** : classification C-Moyennes-Floues multi-centroïdes
- **FFD** : Free Form Deformations
- **FREAK** :Fast Retina Keypoint
- **FT** : Fonction de transformation
- **GL** : Niveau de Gris
- **ICP** : Iterative Closest Point
- **IM** : Image Multispectrale
- **Ims** : Image source
- **Imt** : Image transformée
- **IRM** : l'imagerie par ré- sonance magnétique
- **KDE** :Kernel Density Estimation
- **ORB** : Rotated BRIEF
- **PC-FCMMulticentroïde** : Possibilistic Clustring FCM Multicentroïde
- **PCM** : Possibilistic C-means
- **PDC** : Points De Contrôle
- **PDDP** : Principal Direction Divisive Partionning
- **PL** : Niveau possibiliste
- **PSGRA** : Approche de recalage géométrique supervisé possibiliste

- **PSVM** : Possibilistic SVM
- **SIFT** : Scale-Invariant Feature Transform
- **SURF** : Speed Up Robust Feature
- **SVM** : Machines à Vecteurs de Support
- **T** : Indice de Tang
- **TC** : Temps de calcul
- **TEP** : Tomographie par Emission de Positons
- **TPS** : Thin-Plate Splines
- **WL** : Indice de Wu-Li

# Introduction générale

Le traitement d'images, vise à développer des méthodes permettant d'améliorer la qualité d'images en sortie de capteurs, d'extraire des informations élémentaires utiles leurs interprétations et aussi, de réaliser des opérations, dites de haut niveau, qui assurent une interprétation sémantique.

Toutes ces méthodes peuvent être répertoriées dans deux catégories : les méthodes aveugles et les méthodes guidées par les connaissances. La première catégorie considère l'image comme un tableau de données numériques bidimensionnel ayant un lien de voisinage spatial, 2D, et propose un ensemble de méthodes de traitement générique applicables sur tout type d'images. En revanche, les méthodes de traitement guidées par les connaissances visent à étendre les méthodes aveugles en y intégrant des connaissances liées aux capteurs physiques ayant engendré des images et/ou des connaissances ayant un sens sémantique lié à la scène observée (connaissances a priori sur le contenu, i.e., des modèles a priori).

L'une des questions encore ouverte dans ce domaine concerne la façon d'intégrer les différentes formes de connaissances au niveau des méthodes de traitement. A cet effet, l'application de la théorie des ensembles flous a été proposée sous l'angle de l'intégration des connaissances exprimées sous la forme de variables linguistiques et désignant des concepts ambigus explicités par les experts. Cette application s'est limitée à une utilisation directe de la théorie des ensembles flous et de la logique floue (i.e., réaliser la projection des niveaux de gris, via des fonctions d'appartenance, afin d'obtenir des images dites « floues »).

La théorie des possibilités constitue une extension de la théorie des ensembles flous en termes de représentation des connaissances liées aux différentes formes d'imperfection de l'information et apporte des outils de raisonnement et d'aide à la décision. Des études récentes ont prouvé des potentialités de l'application de cette théorie dans différents domaines d'ingénierie.

Dans le cadre de ce travail de recherche, nous proposons d'exploiter la théorie des possibilités dans la thématique de recalage d'images. Ce choix est justifié par la recherche d'un nouvel espace de représentation sémantique qui permet d'exploiter au maximum des connaissances afin d'extraire des primitives du système de recalage de bonne qualité (en nombre suffisant et évitant les faux amers).

Les approches existantes en recalage d'images reposent sur des informations aux niveaux des capteurs pour l'extraction des primitives ; ces informations sont insuffisantes pour une meilleure caractérisation. L'utilisation limitée aux connaissances du niveau de capteur peut affecter la qualité du rendu du système de recalage. C'est ainsi que nous visons, dans ce travail, à appliquer une phase de projection des connaissances au niveau des capteurs afin d'obtenir un ensemble d'images au niveau sémantique appelées "Cartes de possibilités" et d'utiliser ces cartes dans le

processus de recalage. Chaque carte contient un seul contexte qui est présenté par les pixels ayant des valeurs de possibilité attribuées selon leurs possibilités d'appartenance à une classe sémantique donnée.

Nous distinguons dans la littérature deux familles d'approches de recalage, l'approche géométrique (aussi appelé : Recalage Haut niveau), et l'approche iconique (aussi appelé : Recalage Bas niveau). Nous nous intéressons particulièrement à l'approche géométrique car elle est considérée naturelle puisqu'elle procède de façon analogue à l'approche de raisonnement humain conscient.

Un processus de recalage de l'approche géométrique est réalisé en trois phases principales. La première phase consiste à détecter un ensemble de primitives, appelées points d'intérêt. La deuxième phase se concentre sur la description des primitives des deux images à recaler ; l'image source et l'image cible, en utilisant un descripteur selon la méthode de recalage utilisée. La dernière phase consiste à déterminer la fonction de transformation optimale pour la mise en correspondance des deux images à recaler.

Les méthodes de recalage d'image de l'approche géométrique fonctionnent au niveau pixelique (i.e., Niveau de gris) ; les informations extraites à ce niveau peuvent présenter un conflit lors de la mise en correspondance des primitives. Ceci va se traduire par une imperfection qui engendre des problèmes de confusion et une transformation imprécise.

Pour surmonter les limites de l'approche de recalage géométrique, nous proposons d'utiliser une représentation des connaissances possibilistes et de conduire le processus de recalage d'images géométrique au niveau d'une connaissance semi-sémantique (c'est le niveau possibiliste). La nouvelle approche de recalage géométrique proposée présente deux contextes : le contexte supervisé et le contexte non supervisé. Dans un contexte supervisé où les connaissances préalables concernant le contenu sémantique des images sont supposées disponibles, les cartes sémantiques des images source et cible sont fournies par un expert. Dans un contexte non supervisé, aucune connaissance préalable n'est disponible concernant le contenu sémantique des images ; ainsi, cette connaissance sémantique devrait être «extraite» en utilisant certaines méthodes de classification.

Les deux contextes de l'approche de recalage géométrique proposée permettent une réduction du temps de calcul et un maintien de performances de haut niveau (en termes de réduction du nombre de faux amers, de minimisation de la sensibilité au bruit et d'amélioration de la précision).

Dans ce travail de recherche nous avons proposé deux méthodes basées sur la théorie des possibilités pour chaque contexte. Pour le contexte non supervisé, nous proposons une méthode de classification possibiliste basée sur l'approche SVM (PSVM) et pour le contexte non supervisée nous proposons une méthode de clustering possibiliste basée sur l'approche des multicentroides (PC-Multicentroïde). Les deux méthodes de classification possibiliste proposées permettent d'avoir deux ensembles de classes des deux images à recaler. Ces derniers sont importants pour la performance de la phase de projection.

Ce document est organisé en cinq chapitres comme suit : Le premier chapitre, intitulé "ÉTAT DE L'ART" présente un état de l'art sur les systèmes d'acquisition des images, sur le recalage d'images ainsi sur les familles d'approches. Nous distinguons deux familles d'approches : géométrique et iconique. Nous soulignons que les critères de similarité sont importants pour la mise en correspondance des primitives ; nous présentons dans ce chapitre un état de l'art sur les méthodes existantes pour la mise en correspondance des primitives géométrique. Nous présentons ainsi les types de transformation et nous terminons par les méthodes d'optimisation.

Le deuxième chapitre est intitulé "RECALAGE D'IMAGES : APPROCHE GÉOMÉTRIQUE". Dans ce chapitre nous introduisons le principe de base du recalage géométrique. Nous présentons les phases du recalage et nous terminons par la présentation des méthodes de recalage géométrique existantes.

Le troisième chapitre est intitulé "ESTIMATION DES DISTRIBUTIONS DES POSSIBILITES POUR LE RECALAGE GEOMETRIQUE". Il comporte les fondements de base de notre approche proposée. Nous commençons par la présentation de l'information au niveau des images. Cette dernière peut présenter un niveau imperfection important ; d'où il est important de consacrer une section pour la représentation des données numériques des connaissances imparfaites. Ensuite, nous résumons les concepts essentiels de la théorie des possibilités avec ses fondements. Nous entamons par la suite notre approche proposée qui comporte les deux contextes ; un contexte supervisé et un contexte non supervisé permettant la génération des cartes de possibilités.

Le quatrième chapitre intitulé "SYSTEME DE RECALAGE POSSIBILISTE" présente nos contributions qui sont liées à la fusion des connaissances sémantiques avec les connaissances au niveau de gris pour obtenir une base semi-sémantique permettant d'obtenir un recalage plus fiable en termes de précision. Nous avons aussi proposé une méthode de classification possibiliste supervisée basée sur l'approche de SVM et une méthode de clustering possibiliste basée sur la méthode FCM-multicentroïde.

Nous terminons avec le cinquième chapitre intitulé "EXPERIMENTATION ET EVALUATION DU SYSTEME DE RECALAGE POSSIBILISTE" ce chapitre comporte les résultats d'expérimentations des différentes applications ; contexte supervisé, contexte non supervisé et recalages possibiliste multimodale. Nous avons utilisé des bases d'images satellitaires et médicales.

Nous clôturons ce document par la conclusion et la proposition de certaines perspectives.

# ÉTAT DE L'ART

## Sommaire

<b>1.1</b>	<b>Introduction</b>	<b>5</b>
<b>1.2</b>	<b>Systèmes d'acquisition des images</b>	<b>5</b>
<b>1.3</b>	<b>Représentation de l'information d'une image</b>	<b>6</b>
1.3.1	Analyse à l'échelle du pixel	7
1.3.2	Analyse de contours	7
1.3.3	Analyse de régions	8
<b>1.4</b>	<b>Recalage d'images</b>	<b>8</b>
1.4.1	Définition et terminologie	9
1.4.2	Paramètres et champ de déformation	11
<b>1.5</b>	<b>Familles d'approches du recalage</b>	<b>12</b>
1.5.1	Approche géométrique	12
1.5.1.1	Présentation de l'approche géométrique	13
1.5.1.2	Avantages de l'approche géométrique	14
1.5.1.3	Limites de l'approche géométrique	15
1.5.2	Approche iconique	15
1.5.2.1	Présentation de l'approche iconique	15
1.5.2.2	Avantage de l'approche iconique	16
1.5.2.3	Limites de l'approche iconique	16
1.5.3	Approche hybride	16
<b>1.6</b>	<b>Les critères de similarité</b>	<b>16</b>
1.6.1	Critère de similarité : Approches Géométriques	17
1.6.2	Critère de similarité robuste	17
1.6.2.1	Norme Euclidienne pour 2 points	18
1.6.2.2	Algorithme ICP (Iterative Closest Point)	18
1.6.2.3	Moyenne du carré de la distance	18
1.6.2.4	Les cartes de distances	18
1.6.2.5	Distance de Hausdorff	18
1.6.3	Critère de similarité : Approches iconiques	19
1.6.3.1	Identité	19
1.6.3.2	Affine	19
1.6.3.3	Fonctionnelle	19
1.6.3.4	Dépendance	20
<b>1.7</b>	<b>Type de transformation</b>	<b>20</b>
1.7.1	Approche paramétrique	20

1.7.1.1	Transformation globale . . . . .	20
1.7.1.2	Transformation semi-locale . . . . .	21
1.7.1.3	Régularisation . . . . .	21
1.7.2	Approches non-paramétriques . . . . .	22
1.7.2.1	Modèles élastiques . . . . .	22
1.7.2.2	Modèles fluides . . . . .	22
1.7.2.3	Modèles de flux optique . . . . .	22
1.7.2.4	Modèle de diffusion . . . . .	22
<b>1.8</b>	<b>Optimisation . . . . .</b>	<b>23</b>
1.8.1	Méthodes directes . . . . .	23
1.8.2	Méthodes exhaustives . . . . .	23
1.8.3	Méthodes numériques itératives . . . . .	23
1.8.4	Méthodes stochastiques . . . . .	23
<b>1.9</b>	<b>Conclusion . . . . .</b>	<b>24</b>

## 1.1 Introduction

Le traitement d'images est une discipline de l'informatique et des mathématiques appliquées qui étudie un ensemble d'images numériques et leurs transformations. De ce fait, elle présente un ensemble de méthodes opérant sur l'information numérique, afin d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées pertinentes pour atteindre un objectif donné.

Le traitement d'une image se fait après les étapes d'*acquisition* et de *numérisation*, assurant des transformations de l'image et de la partie de calcul de cette dernière afin de permettre une interprétation de l'image traitée.

En fait, le mode et les conditions d'acquisition et de numérisation des images traitées conditionnent largement les opérations qu'il faudra appliquer pour l'extraction des informations. Plusieurs paramètres sont pris en compte lors de l'acquisition d'une image, les principaux étant :

- La résolution et le mode de codage utilisé lors de la numérisation, qui déterminent le degré de précision des mesures de dimensions,
- Les réglages optiques choisis lors de l'acquisition qui déterminent la netteté de l'image,
- Les conditions d'éclairage, qui déterminent une partie de la variabilité des images traitées,
- Le bruit de la chaîne de transmission d'image.

Dans ce chapitre, nous présentons les systèmes d'acquisition ainsi que la problématique de recalage d'images.

## 1.2 Systèmes d'acquisition des images

L'acquisition d'une image constitue l'un des nœuds essentiels de toute chaîne de conception et de production d'une image. Cette dernière subit une transformation qui lui rend lisible et manipulable par un système d'acquisition. Le passage de cet objet externe (image source) à sa

représentation interne (dans l'unité de traitement) se fait grâce à une procédure de numérisation. Ainsi, une image numérisée par un système d'acquisition donnée constitue un ensemble d'informations structuré selon un nombre de paramètres, tels que :

- **La dimension de l'image** : Présentant la taille de l'image matricielle en calculant le nombre de pixels. Chaque pixel est représenté par une valeur numérique indiquant la valeur de l'intensité lumineuse (pixels) ;
- **La résolution de l'image** : C'est la mesure de la finesse des détails d'une image, pour une dimension donnée ;
- **Le bruit** : Un bruit dans une image est considéré comme un phénomène de variation brusque de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur ;
- **Le Contraste** : C'est l'opposition marquée entre deux régions d'une image. Il est défini en fonction des luminances de deux zones d'une image ;
- **La Luminance** : C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface.

De cet effet, les systèmes d'acquisition ne cessent de progresser et d'améliorer leurs performances tant au niveau de la qualité que de la vitesse de production des images pour assurer une meilleure acquisition qui va être exploitée par des méthodes de traitement d'images. Les résultats des traitements sur les images dépendent en partie de la qualité d'image, qui est fortement liée à la fiabilité de l'acquisition qui dépend à son tour du capteur utilisé.

Ces méthodes de traitement concernent plusieurs domaines notamment la médecine, la télé-détection, la paléontologie, et l'archéologie, . . .

Pour tous ces domaines, une problématique majeure est liée à l'analyse d'un ensemble d'images relativement à un référentiel commun. Un tel *recalage* permet la superposition spatiale des structures présentes dans deux images (appelée : image source et image cible) qui peuvent éventuellement être acquises par des capteurs différents.

L'hétérogénéité des systèmes d'acquisition génère des images de modalités différentes où chaque modalité apporte un lot d'informations pertinentes et présente un risque de difficultés que nous pouvons rencontrer lors de l'interprétation des informations issues des images à recaler.

Toutefois, nous distinguons plusieurs approches de recalage classifiées selon la nature de l'information extraite à partir des deux images à recaler qui dépend du système d'acquisition utilisé. Chacune des approches vise à trouver un critère de similarité permettant de quantifier la ressemblance entre les deux images à recaler, et de chercher le modèle de déformation et la stratégie d'optimisation dans l'estimation des paramètres du modèle.

### 1.3 Représentation de l'information d'une image

Une image peut être interprétée comme une matrice à deux dimensions de valeurs lumineuses (i.e., au niveau de gris) ou de couleur. Une telle interprétation permet de représenter une image

de différentes manières. En effet, les images peuvent être vues comme un ensemble de pixels, caractérisés par leur intensité lumineuse variable, représentant une scène concrète ou abstraite. Elles peuvent être modélisées comme une fonction  $f$  dont les valeurs  $f(x, y)$  varient selon les coordonnées spatiales. Une image est également un signal  $2D$ , ou encore un ensemble de textures ou motifs agencés d'une manière spécifique permettant de décrire la scène. Ces différents points de vue sont autant de bases de représentation. Elles vont mettre en avant différents types d'informations qui conduisent à différents types d'analyse des images numériques.

Les méthodes d'analyse d'images ont un point en commun : la caractérisation des images à étudier, que cette caractérisation soit globale ou locale. Cette dernière passe par une analyse à l'échelle des pixels (histogrammes, matrices de co-occurrence), des formes (attributs géométriques) ou encore des régions (motifs, textures).

### 1.3.1 Analyse à l'échelle du pixel

Nous considérons une image  $I$  et un ensemble de pixels  $P$ . Une possibilité pour caractériser  $I$  est de considérer les éléments de  $P$  sans prendre en compte un ordonnancement précis. Des notions statistiques telles que la moyenne, la variance, l'écart type et la covariance sont des outils basiques très utilisés. De ces notions découle tout un ensemble d'outils. Le critère de Woods [Woods *et al.*, 1992], le rapport de corrélation [Roche *et al.*, 1998] ou l'information mutuelle sont des outils de mesures fondés sur le dénombrement et les proportions de pixels de différentes intensités lumineuses.

Une image peut être caractérisée par l'histogramme des niveaux de gris. Ce dernier représente le nombre d'occurrences de chaque nuance de gris. Dans l'histogramme, toute information sur la distribution spatiale des pixels est perdue. Néanmoins, l'histogramme peut être utilisé efficacement pour la segmentation de certaines images.

La limite des méthodes reposant sur l'histogramme est la pauvreté des informations que l'on peut extraire à cette échelle, une image étant bien plus qu'un ensemble de pixels sans organisation spécifique. Certains outils prennent en compte les différentes formes de relations entre pixels ; intensité ou position comme les matrices de co-occurrence par exemple introduites par Haralick [Matrix, 1992]. Une matrice de co-occurrence mesure la probabilité d'apparition des paires de valeurs de pixels situés à une certaine distance l'un de l'autre dans l'image.

Ces méthodes caractérisent une image à partir de sa constitution ou bien à travers l'organisation des éléments constitutifs qui la composent. Ce type d'analyse permet de caractériser au niveau local ou global. Pour qu'une méthode de classification puisse être élaborée à partir de ces méthodes, les variations intra-classe doivent être faibles.

### 1.3.2 Analyse de contours

L'analyse de contour constitue l'analyse de formes qui est une description d'une image par la recherche des différentes régions qui la composent, ou par la forme du contour de ces dernières. Cette analyse passe par une phase de délimitation des objets, appelée segmentation [Bolon *et al.*, 1995] [Jędzierowska *et al.*, 2019].

De nombreux outils permettent de caractériser un contour et d'effectuer des comparaisons, que ce soit pour identifier un objet inconnu ou pour comparer deux objets [Bossart, 2024].

### 1.3.3 Analyse de régions

Une analyse d'une image peut s'effectuer région par région. Il existe différentes méthodologies pour la réalisation de cette analyse [Bres *et al.*, 2003]. En effet, elle peut reposer sur les mêmes principes que l'analyse de l'image à l'échelle du pixel. Dans ce cas, l'analyse est effectuée au niveau local. Soit  $P$ , l'ensemble des pixels d'une image  $I$ , une région est un sous-ensemble de pixels connexes de l'ensemble  $P$ . Elle peut être carrée, circulaire, ou de toute autre forme pour une étude locale régulière. Les formes régulières vont permettre la génération d'un vecteur de descripteurs locaux, une forme plus complexe pré-segmentée permet d'analyser un ensemble cohérent. Les différentes régions constituant l'image peuvent être regroupées durant une phase de classification. Les résultats locaux ainsi récupérés permettent d'obtenir une « carte » de la composition de l'image et donc de définir au mieux les sous-ensembles constitutifs de l'image. Nous distinguons divers méthodes telles que la croissance de régions et la méthode par division et fusion [Boucher, 2013].

D'autres méthodes plus complexes existent et intègrent davantage l'organisation des variations lumineuses, comme les transformées ou les champs de Markov [Descombes, 1993] ou encore l'analyse fondée sur l'étude de motifs dans l'image.

Tout traitement appliqué sur des images nécessite une ou plusieurs analyses de l'image. Le choix du type de l'analyse se base sur les spécificités du type de traitement à appliquer [Caloz et Collet, 2011].

Notre travail concerne le recalage d'image qui peut être réalisé en fonction de plusieurs types d'analyse selon l'approche de recalage choisie.

## 1.4 Recalage d'images

Le recalage d'images est un problème de mise en correspondance de deux scènes observées via deux images.

Ce problème continu à intéresser les chercheurs et présente un enjeu de taille pour plusieurs systèmes d'analyse et d'interprétation d'images [Bloch, 2020] [Guilloteau, 2021] [Guerroumi, 2019]. Ainsi, il n'existe pas de problème unique de recalage d'images mais plutôt une variété d'interprétations visuelles dont nous donnons intuitivement les classifications possibles [KAAZAOUI et KAAZAOUI, 2018].

Le recalage d'images peut se définir comme la recherche de la transformation spatiale des points d'une image, en s'appuyant sur les pixels physiques correspondants d'une autre image, pour favoriser un alignement au tour d'un même repère. En recalage, nous parlons souvent de deux images, l'une sert de référence, l'autre étant l'image à transformer. L'image de référence est aussi appelée image cible et l'image à transformer est appelée image source ou image flottante.

Le recalage d'images peut se résumer en une phrase, c'est le déplacement ou la déformation d'une image de manière à ce qu'elle ressemble à une autre. En fait, il y a de multiples raisons pour lesquelles nous pouvons nous intéresser à ce genre de traitement, et pratiquement chacune a

des priorités différentes.

### 1.4.1 Définition et terminologie

Dans l'état de l'art dressé par Lisa Brown [Brown, 1992], la problématique et la définition du recalage d'images ont été introduites comme suit :

“ The registration problem is the task involved in finding the optimal spatial and intensity transformations so that the images are matched with regard to the misregistration source. The intensity transformation is frequently not necessary, except, for example, in cases where there is a change in sensor type or where a simple look up table determined by sensor calibration techniques is sufficient. ”

“ Image registration can be defined as a mapping between two images both spatially and with respect to intensity. If we define these images as two 2-dimensional arrays of a given size denoted by  $I$  and  $J$  where  $I(x, y)$  and  $J(x, y)$  each map to their respective intensity values, then the mapping between images can be expressed as :

$$J(x, y) = g(I(f(x, y))) \quad (1.1)$$

Where  $f$  is a 2D spatial coordinate transformation,  $(\dots)$  and  $g$  is a 1D intensity transformation.”

Dans la suite de ce document, les transformations d'intensité  $f$ , et spatiale  $g$ , sont regroupées dans une transformation globale appelée  $T$ .

Soit deux images  $S$  (*source*) et  $C$  (*cible*).

L'image  $S$ , utilisée comme modèle, est appelée image de référence. L'image  $C$  qui va subir la déformation est appelée l'image traitée.

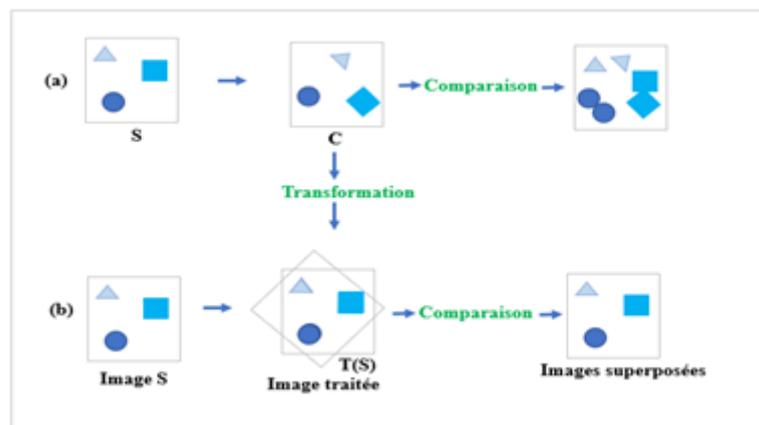


FIGURE 1.1 – Comparaison d'images avant (a) et après recalage (b)

Le recalage est la mise en correspondance dans un même référentiel de deux ou plusieurs objets afin de pouvoir les comparer ou en extraire des informations complémentaires.

Soit deux images  $\mathbf{S}$  (*source*) et  $\mathbf{C}$  (*cible*). Nous considérons  $\mathbf{T}$  une transformation géométrique applicable à  $\mathbf{S}$ .

Nous cherchons la transformation géométrique  $\mathbf{T}'$  maximisant une mesure de similarité ou minimisant une mesure de dissimilarité  $\Delta$  entre  $\mathbf{C}$  et  $\mathbf{T}(\mathbf{S})$  [Tarel, 1996][Huet et Philipp, 1998]

L'équation de recalage est définie comme suit :

$$T' = \operatorname{argmin}_{T \in E} \Delta(C, T(S)) \quad (1.2)$$

Avec

- $T'$  : la transformation recherchée
- $\operatorname{argmin}_T$  : fonction d'optimisation
- $\Delta$  : Mesure de similarité
- $C$  : image de référence (comme une fonction)
- $S$  : image flottante (comme une fonction)
- $E$  : espace de recherche

D'après l'équation ci-dessus nous pouvons classifier les méthodes de recalage selon trois critères principaux :

- 1- La mesure de dissimilarité entre les objets :  $\Delta$  ;
- 2- Le type de transformation appliquée à la source :  $\mathbf{T}$  ;
- 3- l'algorithme d'optimisation : **argmin**.

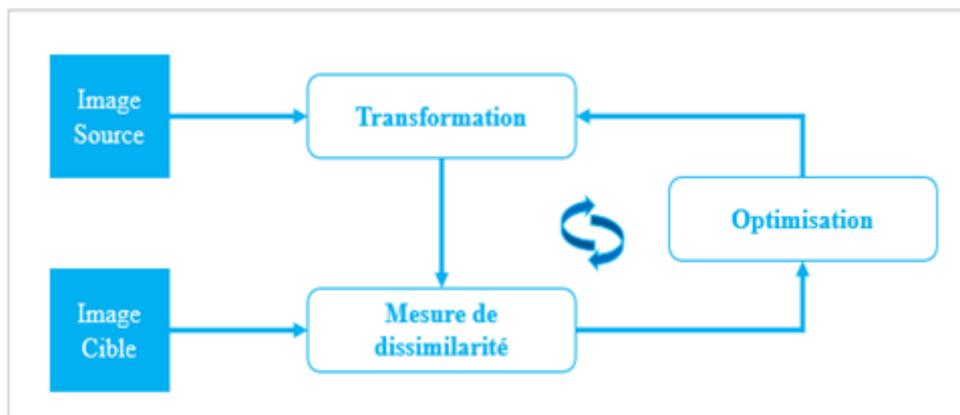


FIGURE 1.2 – Principe général du recalage de deux images : Processus de recherche  $T'$

Les domaines d'application des méthodes de recalage couvrent plusieurs niveaux tels que l'agriculture, l'océanographie, la géologie, la photographie, le traitement vidéo, l'imagerie médicale, etc..

Le recalage peut se faire entre des données issues d'un même système d'acquisition, c'est le recalage monomodal, par opposition au recalage multimodal.

Les problèmes soulevés par le recalage multimodal sont découplés car les données cibles et sources ne sont plus forcément de même nature.

Exemple : En imagerie médicale, les différentes modalités d'imagerie offrent des données :

- Des dimensions différentes (2D, 3D, ...),
- Statiques ou dynamiques,
- Des contenus informatifs différents (anatomique, fonctionnel, métabolique, ...),

- Une résolution spatiale et temporelle variable,
- Acquisées dans des conditions d'examen variables.

### 1.4.2 Paramètres et champ de déformation

La variabilité des déformations, la diversité des images à recalcr pouvant relier deux images ainsi que le bruit présent sur les images font qu'il est impossible de concevoir une méthode de recalage universelle. Chaque méthode doit prendre en compte le type de déformation présumé ainsi que le bruit présent et enfin la précision nécessaire à la comparaison des images ou à l'application qui en sera faite. Les domaines applicatifs pouvant profiter des avantages d'une étape de recalage, dans le but d'effectuer une analyse conjointe d'images de manière automatisée, sont très nombreux. Nous trouvons des applications dans le cadre du suivi d'objet [thi, 1996], utile pour la surveillance vidéo [Kim *et al.*, 2005] par exemple ; ou dans la reconstitution de panorama par mosaïques d'images [Ardeshir, 2005], technique utilisée pour agencer des photos satellitaires ; et également dans l'élaboration de systèmes d'aide au diagnostic en imagerie médicale [Bde Boor, 2001]. L'ouvrage [Ardeshir, 2005] regroupe les avancées du recalage pour diverses applications, que ce soit en 2D ou en 3D.

Dans l'état de l'art [Brown, 1992][West *et al.*, 1997][Guo *et al.*, 2006], nous relevons les critères suivants pour les méthodes de recalage.

- La dimension (1D, 2D, 3D et dimension temporelle),
- La modalité des images (monomodales, multimodales),
- L'objet recalé (tissu vivant sur une image médicale, bâtiments sur une image satellite...),
- La relation existante entre les objets (inter-sujets, intra-sujet, atlas),
- Les primitives permettant d'évaluer la transformation nécessaire (extrinsèques, intrinsèques),
- Le niveau d'automatisation (automatique, semi-automatique ou manuel),
- Le type de déformation (rigides, non-rigides),
- L'échelle des déformations (locales, globales, multiples),
- La procédure d'optimisation (méthode permettant de converger vers le meilleur résultat).

Comme il a été précisé dans la définition du recalage, certains critères sont interdépendants. Les primitives choisies vont par exemple dépendre de la dimension et de la modalité des images ; le type de déformation dépend du type d'objet recalé.

Les relations de dépendances naturelles qui existent entre ces critères ont débouché sur l'élaboration de méthodes spécifiques à certaines combinaisons de critères. Parmi toutes ces classifications et suivant l'équation de recalage Eq (1.2), nous avons trois critères principaux qui s'imposent pour différencier ces méthodes :

- 1- Le type de transformation appliquée,
- 2- La mesure de similarité,
- 3- La méthode d'optimisation utilisée.

## 1.5 Familles d'approches du recalage

Il est difficile de recenser toutes les méthodes de recalage d'images qui ont été proposées dans la littérature. Les travaux de recherche de [Brown, 1992], [Zhang, 1993], couvrant plusieurs domaines de la vision artificielle, ainsi que ceux de [Van Den Elsen *et al.*, 1994] [Taylor *et al.*, 2016] [Maintz *et al.*, 1998], spécifiques au traitement d'images médicales, constituent d'excellentes synthèses techniques.

Deux classes de primitives se distinguent, définissant deux grandes approches de recalage [Xia *et al.*, 2013] :

- La famille d'approches géométriques qui s'appliquent pour apparier au mieux des primitives géométriques (points, lignes, surfaces) ;
- La famille d'approches iconiques (ou luminance) qui utilisent l'information de luminance (i.e., niveaux de gris).

La figure ?? illustre les approches de recalage. Les approches géométriques [Chen et Tian,

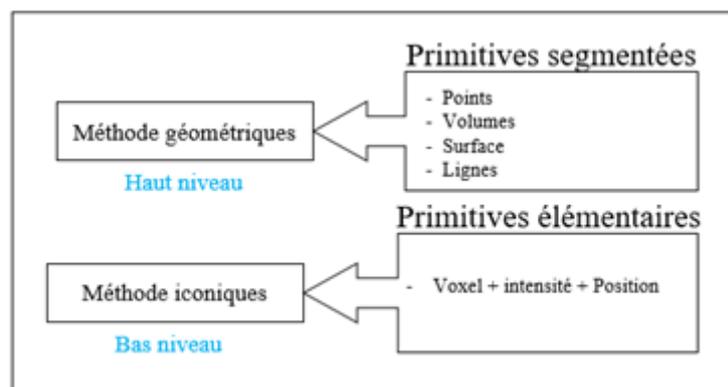


FIGURE 1.3 – Approches de recalage

2009] permettent de répondre à certaines limites des méthodes iconiques.

### 1.5.1 Approche géométrique

L'étape de segmentation consiste à identifier les primitives dans les images. La difficulté concerne l'identification de ces primitives homologues. La segmentation peut se faire soit manuellement, soit automatiquement.

La segmentation manuelle est encore très courante en imagerie médicale. Les primitives sont extraites et labellisées à partir de l'expertise du radiologue.

Ces primitives peuvent être des zones propres à l'anatomie du patient, c'est ce qu'on appelle de nature intrinsèque, ou des marqueurs stéréotaxique utilisés pour fournir une invariance topologique, appelées aussi des primitives extrinsèques [Bde Boor, 2001]. Par contre, en segmentation automatique, il faut repérer les invariants différentiels comme les coins et les courbes stables. Rappelons que notre objectif, dans cette synthèse, est de reproduire le processus humain pour l'extraction des primitives.

Plusieurs études ont été déjà menées sur les détections automatiques des points extrémaux [Rangarajan *et al.*, 1997], des lignes de crête [Borgefors et di Baja, 1988], des surfaces [Roche

*et al.*, 1998][Acosta *et al.*, 2018] et des volumes[Malandain *et al.*, 1994].

La deuxième étape est la mise en correspondance. A partir de la détection de ces primitives, une multitude d'approches permettent de faire le recalage entre autres la minimisation de la distance euclidienne, la minimisation de la carte de distances[Mangin *et al.*, 2004] et les algorithmes basés sur des correspondances floues[Giraud *et al.*, 2020].

La Figure ?? présente les points homologues des deux images. Nous pouvons réaliser la mise en correspondance en cherchant par exemple le minimum de la distance quadratique entre chaque couple de points [Taylor *et al.*, 2016].

Ainsi, la qualité du recalage dépend du nombre de primitives extraites. Le résultat du recalage dépend aussi du résultat de la segmentation. De plus, intuitivement, pour un recalage multimodal avec des images de basse résolution comme les images issues de la tomographie par émission de positons (TEP) et de la tomographie par émission monophotonique (TEMP), l'approche géométrique s'avère moins efficace.

### 1.5.1.1 Présentation de l'approche géométrique

Les méthodes géométriques sont peut-être les plus naturelles car elles procèdent de façon analogue à au raisonnement humain conscient. Dans un premier temps, il s'agit d'identifier dans les images des caractéristiques géométriques communes ; caractéristiques que l'on appelle des primitives et qui peuvent être des points, des lignes, des surfaces, des volumes, des repères orientés, voire des descriptions structurées mettant en jeu des relations entre éléments. Ayant ainsi réduit le signal visuel à une information géométriquement pertinente, on cherche la transformation spatiale qui apparie au mieux les différentes primitives. Les méthodes géométriques reposent donc sur deux étapes bien distinctes, qui sont d'ailleurs généralement menées de façon complètement indépendante. La première étape, dite de segmentation, est souvent la plus problématique dès lors que l'on souhaite la réaliser automatiquement. Elle requiert d'extraire des primitives qui soient significatives, ce qui peut s'avérer difficile si les images sont fortement bruitées (par exemple, des images ultra sonores). Mais ce n'est pas tout car il faut encore que ces primitives correspondent aux mêmes réalités physiques dans les deux images ; cette deuxième contrainte est particulièrement délicate dans un problème de recalage multimodal.

La mise en œuvre des méthodes géométriques nécessite une forte connaissance a priori sur la nature des objets imagés, ce qui rend leur champ d'application très spécifique. Notons qu'il n'est pas interdit de demander à l'utilisateur de réaliser lui-même l'étape de segmentation. Bien que nous ayons tendance à penser que les outils de vision artificielle devraient toujours être complètement automatiques, nous n'en reconnaissons pas moins que le raisonnement humain est sans aucun doute l'algorithme de recalage le plus fiable au monde peut-être faut-il s'en réjouir. Dans un même ordre d'idée, on peut prévoir d'inclure dans les images des marqueurs stéréotomiques fixés rigidement au patient et dont la détection sera plus aisée. Il s'agit alors, pour reprendre la terminologie de [Van Den Elsen *et al.*, 1994], de primitives extrinsèques par opposition à intrinsèques.

Nous pouvons donner quelques exemples de primitives détectées automatiquement dans un

but de recalage : des points extrémaux [thi, 1996], des lignes de crête [Bardol *et al.*, 2018], des surfaces [Shan *et al.*, 2018], des volumes [Malandain *et al.*, 1994], ou, à un niveau sémantique supérieur, des graphes relationnels distribués [Mangin, 1995][Amit et Kong, 1996][Bardinet *et al.*, 2000].

Nous trouvons d'autres références dans les états de l'art précédemment cités. Après la segmentation des primitives, la deuxième étape est celle du recalage proprement dit, c'est-à-dire le calcul d'une transformation spatiale optimale. Il convient de distinguer le cas où les correspondances entre primitives sont connues à l'avance (primitives labellisées) du cas contraire (primitives non-labellisées), très fréquent lorsque la segmentation est automatique. Les méthodes adaptées au premier cas sont typiquement des méthodes d'ajustement aux moindres carrés ou au sens d'une métrique non-euclidienne. Dans le second cas, les méthodes les plus populaires sont, pêle-mêle, les algorithmes de type prédiction-vérification, la minimisation d'une carte de distances [Borgefors et di Baja, 1988], l'algorithme ICP3 [Zhang, 1994] ou les algorithmes basés sur des correspondances floues [Rangarajan *et al.*, 1997][Rangarajan *et al.*, 1999].

— **Inversibilité** : Dans le cadre des applications médicales, la capacité à produire des transformations inversibles est fondamentale. Le champ de déformation associe à chaque point de l'image source un point de l'image cible. Afin de construire l'image source déformée, il est nécessaire d'associer à chaque position de l'image cible une position de l'image source, en utilisant l'inverse de la transformation estimée. Cette propriété peut être satisfaite en estimant simultanément le champ de déformation et son inverse. Le critère de similarité rend compte, dans ce cas-ci, de l'alignement de l'image source après application du champ de déformation dans l'espace cible et de l'alignement de l'image cible déformée par l'inverse de ce champ dans l'espace source.

— **Symétrie** : La majorité des algorithmes de mise en correspondance sont asymétriques. Cela signifie qu'inter-changer les images sources et cibles a pour résultat des déformations différentes.

Ce choix introduit donc un biais dans la suite du processus et doit être pris en compte. Les approches ne pénalisent généralement pas directement l'asymétrie, mais emploient l'une des stratégies suivantes lorsque le respect de la symétrie est souhaité.

La première solution consiste à employer une fonction objective et un modèle de déformation intrinsèquement symétrique. La deuxième solution consiste à estimer deux transformations au lieu d'une seule. Chaque transformation, projette une image dans un espace commun. La transformation permettant de passer d'une image  $a$  à une image  $b$  est ensuite calculée.

— **Difféomorphisme** : Une transformation est un difféomorphisme si son inverse et elle-même sont différentiables. Un difféomorphisme préserve aussi la topologie. C'est cette contrainte qui apparaît le plus souvent comme souhaitable dans les différentes approches de mise en correspondance.

### 1.5.1.2 Avantages de l'approche géométrique

Nous distinguons plusieurs avantages des approches géométriques [Dhahbi *et al.*, 2008] :

- Optimisation de la complexité temporelle par la gestion de zone d'images plutôt que des détails sur l'image ;
- Pertinente par l'utilisation de données déjà issues de l'image ;

- Remédier aux problèmes des faux amers dans les images initiales et des différences d’intensité entre les 2 images à recaler (Image source, et Image cible).

### 1.5.1.3 Limites de l’approche géométrique

Néanmoins cette famille d’approche possède des limites telles que :

- Un choix des primitives arbitraire ;
- Difficulté de trouver les primitives optimales.
- Difficulté d’estimer, au sein d’une même primitive surfacique ou curviligne, les éventuelles déformations subies à cause et qui ne sont pas pris en charge. [Cottet *et al.*, 2021].

## 1.5.2 Approche iconique

L’approche iconique est basée directement sur les intensités des images. Contrairement à l’approche géométrique, l’étape de compréhension de la géométrie de l’objet ou la segmentation n’est plus nécessaire. Cette approche consiste essentiellement à optimiser un critère de similarité fondé uniquement sur des comparaisons d’intensités [Ilyas, 2021].

La méthode de bas niveau est une autre appellation de l’approche iconique. Cependant, cette approche est plus adaptée en recalage multimodal. Ainsi, c’est à partir des intensités des images qu’on construit la fonction objective (ou fonction de coût). Le processus de recalage se fait par la suite en optimisant cette fonction.

Grâce aux succès des algorithmes fondés sur l’information mutuelle [Chen *et al.*, 2003], cette approche regagne d’intérêt depuis une quinzaine d’années. De plus, Nous pouvons trouver plusieurs variantes de cette approche. Des auteurs proposent deux types d’algorithme de recalage en approche iconique : l’algorithme iconique standard, défini par la mesure de similarité [Zhang *et al.*, 2015] et la régularisation, et l’algorithme reposant sur l’appariement iconique, contraint par l’appariement et le lissage par régularisation On trouve dans [Mangin, 1995] une comparaison d’une douzaine de méthodes de recalage scanner/IRM et TEP/IRM, et on constate un net avantage de l’approche iconique par rapport à l’approche géométrique.

### 1.5.2.1 Présentation de l’approche iconique

Le recalage iconique repose sur l’exploitation de l’intensité des pixels des images [Meurée, 2013].

Si les méthodes géométriques peuvent être considérées comme des approches haut-niveau, les méthodes iconiques sont des approches bas-niveau. Contrairement aux premières, celles-ci ne nécessitent aucune segmentation préalable des images. Elles consistent essentiellement à optimiser un critère de ressemblance ou une mesure de similarité fondée uniquement sur des comparaisons locales d’intensités. Dans ce cas, les primitives guidant le recalage sont les données brutes, c’est-à-dire des vecteurs 4D contenant la position et l’intensité des voxels [Montagnat *et al.*, 1999]. Pour faire un parallèle avec la vision naturelle, nous pouvons dire que les primitives iconiques sont de l’ordre de la sensation alors que les primitives géométriques sont de l’ordre de la perception, voire de la cognition dans le cas de primitives structurées comme les graphes relationnels. Une méthode iconique a deux propriétés essentielles.

D'une part, le choix des primitives est complètement arbitraire : tous les voxels sont *a priori* des candidats valables.

D'autre part, les primitives ne sont pas des entités géométriques ; elles appartiennent à un espace figuratif, différent du monde réel. Ainsi, le critère utilisé pour comparer ces primitives est une mesure de similarité reflétant indirectement une distance géométrique. Remarquons qu'il est possible d'enrichir l'information d'intensité par des informations différentielles d'ordre supérieur (par exemple, le gradient). De telles approches permettent de simuler un recalage géométrique fondé sur des appariements de contours, mais elles restent des méthodes purement iconiques.

### 1.5.2.2 Avantage de l'approche iconique

L'avantage de l'approche iconique peut être résumé selon les deux dimensions suivantes :

- L'exploitation de toutes les données de l'image ; pas de pré-traitement.
- La dimension automatique [Rubeaux, 2011].

### 1.5.2.3 Limites de approche iconique

Néanmoins, cette famille d'approches possède des limites telles que :

- La difficulté de lier deux images ayant des niveaux d'intensité différents ;
- La complexité temporelle élevée ; par la nécessité de calcul de l'intensité de tous les voxels de l'image ;
- L'optimisation difficile à cause de minima locaux.

## 1.5.3 Approche hybride

En revanche, rien n'empêche de choisir des primitives de types différents dans les images à recalcr, notamment des primitives de nature iconiques dans l'une et géométriques dans l'autre [Montagnat *et al.*, 1999]. Les méthodes de ce type peuvent être qualifiées d'hybrides.

Les méthodes hybrides cherchent à combiner les avantages des deux approches, soit en adjoignant des appariements géométriques, potentiellement à longue distance (et donc une mesure de distance), à une mesure de similarité iconique afin d'en gommer les minima locaux, soit en essayant d'établir une carte d'appariements dense à partir de caractéristiques iconiques [Malandain, 2006].

## 1.6 Les critères de similarité

La mesure de similarité est l'élément le plus critique dans le processus du recalage. Cependant, le choix dépend essentiellement de l'approche et de la modalité du recalage.

Une fois définie l'information à utiliser pour guider le recalage, il s'agit d'associer un critère de similarité permettant de définir une distance entre les deux images.

Le critère de similarité [Chailloux, 2007] doit être caractérisé par une valeur extrême minimale ou maximale selon le cas) dès lors que la ressemblance entre les images est la plus forte.

De nombreuses fonctions peuvent être utilisées [Malandain, 2006] :

- Corrélation entre les deux images à recaler [GHORBEL *et al.*, 2009];
- Minimisation de la valeur de la variance des rapports d'intensité entre les deux images à recaler;
- Calcul de la fonction de similarité quadratique;
- Une minimisation de la distance entre les points de d'intérêt;
- Mesure de similarité entre points par mise en correspondance des centres d'inertie des deux ensembles de points (utilisation des quaternions en 3D) [Cottet *et al.*, 2021].

Ces fonctions peuvent être classées en deux catégories en fonction du type d'attribut.

### 1.6.1 Critère de similarité : Approches Géométriques

Plusieurs méthodes sont envisageables pour calculer la distance entre 2 primitives géométriques.

- Norme Euclidienne pour 2 points [Dang *et al.*, 2012];
- Algorithme *ICP* (Iterative Closest Point) [Gobin, 2021];
- Moyenne du carré de la distance;
- Calcul de la distance de *Hausdorff* [Poreba et Goulette, 2014].

### 1.6.2 Critère de similarité robuste

L'objet de l'estimation robuste est précisément de permettre une détermination précise des paramètres d'un modèle bien fini, en présence de pollution par des données nommée « aberrantes », mais néanmoins précieuses, puisque ce sont souvent elles qui portent l'information intéressante. Les méthodes d'estimation robuste font désormais partie des outils utilisés en analyse d'images et en vision par ordinateur. Dans [Kim *et al.*, 2005][Amit et Kong, 1996][Cottet *et al.*, 2021], une synthèse sur le sujet ainsi qu'une présentation des différentes classes d'estimateurs et de leurs propriétés est réalisée.

Une caractéristique importante des estimateurs robustes est leurs points de rupture, qui correspond à la proportion de données pouvant être arbitrairement polluées, sans que cela n'ait d'incidence sur le résultat de l'estimation.

Citons l'exemple de l'estimateur quadratique qui a un point de rupture égal à 0 puisque une seule mesure qui ne suit pas le modèle peut totalement perturber le résultat. L'estimateur des moindres carrés médians [Amit et Kong, 1996], utilisé dans [Gastellu-Etchegorry, 2008] pour le recalage d'images monomodales, est basé sur la minimisation de la valeur médiane des carrés des erreurs résiduelles. Cet estimateur est très performant, puisqu'il est robuste à une contamination des données qui peut atteindre 50%. C'est également le cas de l'algorithme MINPRAN [Cottet *et al.*, 2021].

Ces deux estimateurs appartiennent à la classe des R-estimateurs qui nécessitent un tri des erreurs résiduelles et des techniques d'échantillonnage aléatoire des données. Ceci conduit à des temps de calcul qui sont prohibitifs sur des problèmes de grande taille.

### 1.6.2.1 Norme Euclidienne pour 2 points

Cette méthode est la plus utilisée, grâce à ses propriétés analytiques, elle permet, dans le cas du recalage rigide ou affine, de conduire à une solution analytique pour l'estimation des paramètres de la transformation [Audin, 2021].

### 1.6.2.2 Algorithme ICP (Iterative Closest Point)

L'algorithme ICP est basé sur la Norme Euclidienne mais pour un ensemble de points (de courbes ou de surfaces), il effectue itérativement les étapes suivantes [Favre *et al.*, 2021] :

- **La mise en correspondance** : pour chaque point de données, le voisin le plus proche du jeu de points de modèle est trouvé.
- **La minimisation** : la métrique d'erreur est minimisée.
- **La transformation** : les points de données sont transformés en utilisant le résultat de minimisation.

La contrainte d'arrêt de l'algorithme est le nombre d'itérations ou du changement relatif dans la métrique d'erreur. Dans de nombreux cas, l'algorithme converge bien rapidement, cependant plusieurs problèmes peuvent survenir :

- **Moins de minimas locaux dans la métrique d'erreur** : l'algorithme converge vers l'un des minimums locaux au lieu du minimum global.
- **Bruit et faux amers** : Le bruit entraîne une erreur de la métrique pour ne jamais être nulle.
- **Surpeuplement partiel** : les nuages des points peuvent ne pas ressembler aux mêmes parties d'un objet cherché. Un chevauchement partiel est nécessaire [Kjer *et Wilm*, 2010].

### 1.6.2.3 Moyenne du carré de la distance

Cette méthode consiste à considérer la moyenne du carré de la distance de chaque point de la primitive à recaler par rapport au point le plus proche de la primitive de source dans la direction du centroïde de cette dernière. C'est une autre manière pour construire une distance entre deux ensembles de points [Pelizzari *et al.*, 1989].

### 1.6.2.4 Les cartes de distances

Les cartes de distance sont très efficaces pour calculer la distance entre deux contours : il suffit de calculer la moyenne des valeurs de la carte de distance qui sont superposées avec les contours de l'image à déformer. La distance utilisée pour la construction de cartes de distance est la distance de chanfrein, elle est efficace et rapide [Borgefors *et di Baja*, 1988].

### 1.6.2.5 Distance de Hausdorff

Une autre mesure utilisée pour caractériser la distance entre deux ensembles de points est la distance de Hausdorff [Rucklidge, 1996].

### 1.6.3 Critère de similarité : Approches iconiques

Les méthodes de cette catégorie, se base sur la comparaison des informations obtenues par les niveaux de gris des deux images à recalcr. La relation entre les intensités des 2 images peut être :

#### 1.6.3.1 Identité

Les intensités se correspondent à un bruit blanc gaussien près. Nous utilisons le critère des moindres carrés, la différence absolue des intensités ou la différence inter-images. Nous utilisons la moyenne des carrés pour calculer la similarité entre deux images.

Soient deux images  $I$  et  $J$  de taille  $N = M * L$ , le calcul de la somme des différences d'intensités entre tous les points est donné par :

$$MC(I, J) = \frac{1}{N} \sum_i^n (I_i - J_i)^2 \quad (1.3)$$

Avec :

$I$  : image source,

$J$  : Image cible

Selon Richard et Cohen, cette mesure est robuste aux bruits gaussiens mais pas aux points aberrants (faux amers). Elle est aussi limitée au recalage mono-modale.

#### 1.6.3.2 Affine

Adapté aux images mono-modales. Les intensités des deux images à recalcr suivent une relation linéaire. Le but principal est de maximiser le coefficient de corrélation linéaire.

Les méthodes affines utilisent la corrélation normalisée.

Pour une image de référence  $I$  et une image flottante  $J$ , la corrélation normalisée s'exprime par :

$$NC(I, J) = \frac{\sum_i^n I_i - J_i}{\sqrt{\sum_i^n I_i^2 J_i^2}} \quad (1.4)$$

Avec  $N$  la taille d'une image.

L'utilisation de cette mesure est plus utile avec des images admettant un taux élevé de bruit. En revanche, le temps de calcul avec la corrélation normalisée est plus long que celle de la moyenne des carrés.

#### 1.6.3.3 Fonctionnelle

Ce type est très utiles pour les images multimodales. Pour chaque intensité d'une image donnée nous pouvons associée une valeur unique dans l'autre image. Nous exploitons le critère de *Woods* où nous calculons le rapport de corrélation Eq(1.5).

Rapport de corrélation :

$$\eta^2(i/j) = 1 - \frac{1}{\sigma^2} \sum_i \rho_i \sigma^2 \quad (1.5)$$

Avec :

$$\sigma^2 = \sum_i \rho_i i^2 - \left( \sum_i \rho_i i \right)^2 \quad (1.6)$$

$$\sigma_j^2 = \sum_i \frac{\rho_{i,j}}{\rho_i} i^2 - \left( \sum_i \frac{\rho_{i,j}}{\rho_i} i \right)^2 \quad (1.7)$$

$$\rho = \sum_i \rho_{i,j} \quad (1.8)$$

#### 1.6.3.4 Dépendance

Encore plus générale que la relation fonctionnelle. Les images sont assimilées à des réalisations de variables aléatoires. Le but est alors de trouver leur dépendance grâce à l'histogramme conjoint ou l'information mutuelle. Le calcul d'information mutuelle de deux images est basé sur la densité conjointe de probabilité des niveaux de gris des images. Elle peut être exprimée par Eq (1.9) :

$$IM(i, j) = \sum_{i,j} \rho_{i,j} \cdot \log \frac{\rho_{ij}}{\rho_i \rho_j} \quad (1.9)$$

## 1.7 Type de transformation

Une fois défini le type d'information à utiliser pour guider le recalage et le critère de similarité quantifiant la ressemblance entre deux images, il convient de définir un type de transformation. Le choix de la transformation est orienté par la nature de la correspondance géométrique que l'on désire établir entre les images à recaler. Son choix est fondamental dans le sens où il permettra de définir l'espace de recherche pour l'algorithme de recalage. Nous distinguons deux types de transformations : paramétriques et non-paramétriques.

Dans le cas paramétrique, la transformation peut être de portée variable, ainsi elle peut être « Globale » si elle s'applique à l'ensemble de l'image, ou « semi- locale » si elle résulte d'un ensemble de contributions appliquées à des sous régions de l'image [Delhay, 2006]. Dans le cas non-paramétrique, la transformation est discrète et « locale » car elle est définie explicitement en chaque pixel de l'image. On distingue généralement les transformations rigides et non-rigides qui peuvent se décliner dans les différents cas du global au local. Une description détaillée des différentes transformations est donnée dans [Brown, 1992][Maintz et Viergever, 1998]et [Hill et al., 2001].

### 1.7.1 Approche paramétrique

Nous distinguons trois types de transformation dans la famille d'approches paramétrique ; Transformation globale, transformation semi-locale ou encore transformation régularisée.

#### 1.7.1.1 Transformation globale

Le transformation de type globale, est présentée par des modèles de transformation globale qui ont une influence sur l'ensemble de l'espace citons par exemple les transformations rigides et affines.

Seuls les transformations de types, rotation et translation sont prises en compte, les distances, les angles et le parallélisme sont alors conservés. Ce type de transformation est plus utilisé dans le domaine de l'imagerie médicale. Il sert à recalcr des images d'un même individu acquises à des instants différents ou pour fusionner des images de différentes modalités.

Une transformation affine, permet, en plus des rotations et des translations, l'étirement et le cisaillement des structures des images à recalcr. Dans ce cas, seul le parallélisme est conservé.

La transformation globale est très utiles dans le cas du recalage intra-patient multimodale car le positionnement doit être corrigé [Petitjean, 2013].

En effet, les transformations de types rigides ou/et affines sont aussi dites linéaires car elles peuvent être formulées en considérant les coordonnées homogènes.

### 1.7.1.2 Transformation semi-locale

Une transformation est dite semi-locale ou aussi non-linéaire permet d'appréhender des déformations locales. Elle autorise la variation de la géométrie des structures et de la modification de ses formes globales. Cette transformation peut également appelée transformation *non-rigides* ou déformables. En fait, elle autorise la variation de la géométrie des structures et donc la modification de la forme globale des structures de l'image.

Ce type de transformation est particulièrement intéressant dans le domaine médicale, elle permet d'étudier les variations de forme de structure entre plusieurs patients ou pour étudier l'évolution d'une structure au cours du temps. Dans ce cas, le nombre de Degrés De Liberté (DDL) requis est beaucoup plus important.

- **Fonctions radiales** : Les transformations basées sur les fonctions radiales, constituent un moyen d'appréhender des déformations locales de manière paramétrique. Parmi les fonctions les plus utilisées en recalage géométrique nous citons la méthode Thin-Plate Splines (TPS) [Bookstein et Green, 1993]. Son expression rend compte de la déformation d'une plaque mince dont plusieurs points sont contraints.
- **Déformations de formes libres (Free Form Deformations -FFD)** : Les méthodes *FFD* [Sederberg et Parry, 1986], sont très populaires en synthèse d'images pour la déformation d'objets, elles sont aussi été exploitées en recalage d'image dans le domaine médicale [Schnabel et al., 2001] [Schnabel et al., 2001][Rohlfing et al., 2003].

Cette méthode consiste à considérer une grille régulière de points d'intérêt (*PDC*), l'image étant déformée en agissant sur chacun de ces points de contrôle. Son déplacement opère sur l'ensemble ou une partie du domaine de définition selon la base de fonctions choisie.

En effet, la déformation continue de l'espace se calcule par interpolation des déplacements ponctuels attribués aux *PDC*. L'avantage principal des méthodes *FFD* réside dans leurs aptitudes à estimer des déformations très localisées, ainsi, leurs permettant d'appréhender convenablement les variations locales de forme.

### 1.7.1.3 Régularisation

Le recalage nécessite un nombre de paramètres ; dans le cas où le nombre de paramètres est important, un problème de définition du modèle de transformation peut se présenter.

C'est pour cela que nous appliquons la régularisation de la transformation, il s'agit de pénaliser les variations brusques du champ de déplacement estimé.

La notion de régularisation concerne principalement les méthodes de recalage iconique basées sur l'optimisation au niveau de la complexité temporelle.

Pour les méthodes de l'approches géométriques, la notion de régularisation est portée implicitement par des fonctions d'interpolation. Une description des différentes méthodes de régularisation est donnée en détails dans [Bookstein, 1989][Miller *et al.*, 1993][Gee *et al.*, 1997][Cachier *et al.*, 2003].

## 1.7.2 Approches non-paramétriques

Dans le cas non-paramétrique, la transformation est définie explicitement en chaque pixel de l'image par un vecteur nommé *vecteur de déplacement*.

### 1.7.2.1 Modèles élastiques

Les problèmes de déformations élastiques concernent les modèles élastiques du recalage [Broit, 1981].

Bien que l'hypothèse de déformation élastique soit difficilement justifiable biologiquement, cette approche est relativement séduisante puisqu'elle permet de garantir certaines propriétés aux champs de déformation, notamment de régularité et de conservation de la topologie. En fait, la déformation est contrôlée par les équations de *Navier*. Ces modèles ne sont applicables que pour les déplacements dans le cas l'élasticité linéaire [Chailloux, 2007].

### 1.7.2.2 Modèles fluides

Les modèles fluides sont proposés afin de mettre limites aux problèmes des modèles élastiques [Miller *et al.*, 1999]. L'idée est de considérer l'image non plus comme un matériau élastique dans un cadre lagrangien, mais comme un fluide dans un cadre eulérien. L'inconvénient majeur de ces méthodes par rapport aux méthodes élastiques est la complexité temporelle élevée.

### 1.7.2.3 Modèles de flux optique

Les méthodes de flux optique sont très utilisées pour l'estimation du mouvement [Horn et Schunck, 1981].

Elles établissent un lien direct entre les méthodes de recalage et les méthodes d'estimation de mouvement qui sont considérées comme un cas particulier des méthodes de recalage. Ces méthodes reposent sur l'hypothèse que l'intensité d'un même point reste constante au cours du temps dans une séquence d'images.

### 1.7.2.4 Modèle de diffusion

La méthode de flux optique peut être considérée comme un cas particulier des modèles de diffusion, le plus connu des modèles appliqués au recalage déformable étant celui des démons [Thirion, 1998]. Ce modèle est utilisé pour déformer l'image alors considérée comme une grille

déformable. Les contours des objets de l'image cible sont orientés de l'intérieur vers l'extérieur des objets.

## 1.8 Optimisation

La transformation de recalage résulte de la minimisation d'une fonction de coût qui dépend des primitives (points d'intérêt) sélectionnées. Selon le nombre de *DDL* et des images considérées, la minimisation peut exposer un problème complexe. Afin d'éviter ces problèmes, des stratégies d'optimisation doivent être appliquées afin de garantir l'obtention d'une solution fiable avec une complexité temporelle optimisée. Quatre catégories de méthodes d'optimisation peuvent être distinguées [Rao, 2019] [Press *et al.*, 2007].

### 1.8.1 Méthodes directes

Les méthodes directes sont envisageables lorsque le nombre de paramètres à estimer est faible. L'estimation d'une transformation de type rigide ou affine entre deux images se calcule à partir d'un ensemble d'amers ponctuels, en minimisant la somme du carré des erreurs sur l'ensemble des points d'intérêt. De même, le problème de recalage non-rigide peut se formuler par un problème de « *moindres carrés* » [Rohr, 2001].

### 1.8.2 Méthodes exhaustives

Les méthodes exhaustives consistent à échantillonner un intervalle régulier de l'ensemble de l'espace des paramètres et à retenir la solution optimale. Bien qu'elles permettent d'accéder au minimum global avec une précision définie par le pas d'échantillonnage, elles sont, rarement utilisées à cause de la complexité temporelle élevée.

### 1.8.3 Méthodes numériques itératives

Les méthodes numériques itératives sont plus utilisées lorsque la complexité temporelle à minimiser est une fonction non-linéaire des paramètres à optimiser. Elles reposent sur le calcul du gradient de la fonction de coût (descente de gradient ou descente de gradient conjugué) ou, pour les méthodes dites de *Newton*, sur le calcul du gradient et la matrice *Hessienne*. Les méthodes basées sur le *hessien* du critère sont très efficaces pour une initialisation proche de la solution, mais s'avèrent mal adaptées dans le cas contraire. En revanche, les méthodes par descente de gradient sont plus adaptées pour des initialisations lointaines tandis que leurs vitesses de convergence au voisinage du minimum est considérée faible.

Les méthodes de *Levenberg-Marquardt* permettent de combiner les avantages des deux précédentes sans pour autant garantir un minimum global [Marquardt, 1963].

### 1.8.4 Méthodes stochastiques

Compte aux méthodes stochastiques, les travaux de recherche simulés par [Kirkpatrick *et al.*, 1983] et les algorithmes génétiques proposés par [Goldberg, 1989] présentent les principales méthodes d'optimisation utilisées dans le cadre du recalage, permettant de garantir théoriquement

la convergence vers un minimum global. L'usage de ces méthodes est principalement restreint au cadre du recalage rigide ou affine étant donnée leur faible vitesse de convergence.

## 1.9 Conclusion

Dans ce chapitre, nous avons présenté un état de l'art sur les familles d'approches de recalage, iconiques et géométriques. Nous présentons ainsi un état de l'art que les méthodes permettant la mise en correspondances des primitives en se basant sur le type de critère de similarité considéré pour chacune des deux familles d'approches. Nous avons terminé notre chapitre par les méthodes d'optimisation utilisées pour le recalage d'images.

Dans le chapitre suivant, nous mettons l'accent sur les méthodes de recalage d'images géométrique.

# RECALAGE D'IMAGES : APPROCHE GÉOMÉTRIQUE

---

## Sommaire

<b>2.1</b>	<b>Introduction</b>	<b>25</b>
<b>2.2</b>	<b>Recalage géométrique</b>	<b>26</b>
2.2.1	Techniques de recalage	26
2.2.2	Classification selon la modalité	27
2.2.3	Classification selon les primitives	28
2.2.4	Classification selon le critère de similarité	30
2.2.5	Processus du système du recalage géométrique	30
<b>2.3</b>	<b>Phases de recalage</b>	<b>31</b>
2.3.1	Apport du recalage géométrique	31
2.3.2	Facteurs d'un système de recalage	32
2.3.2.1	Extraction des primitives	32
2.3.2.2	Extraction des points d'intérêts	32
2.3.2.3	Extraction des contours	33
2.3.2.4	Extraction des régions	33
<b>2.4</b>	<b>Méthodes de recalage géométrique</b>	<b>34</b>
2.4.1	Méthode SIFT (Scale-Invariant Feature Transform)	34
2.4.2	Méthode SURF (Speed Up Robust Feature)	35
2.4.3	Méthode BRIEF (Binary Robust Independent Elementary Features)	35
2.4.4	Méthode ORB (Rotated BRIEF)	35
2.4.5	Méthode BRISK (Binary Robust Invariant Scalable Keypoints)	36
2.4.6	Méthode FREAK (Fast Retina Keypoint)	36
2.4.7	Méthode Corner	37
2.4.8	Méthode KAZE	37
2.4.9	Méthode AKAZE (Accelerated KAZE Features)	37
<b>2.5</b>	<b>Évaluation des méthodes de recalage géométrique</b>	<b>37</b>
<b>2.6</b>	<b>Conclusion</b>	<b>39</b>

---

## 2.1 Introduction

La diversité des domaines d'application possibles, et la variété des déformations, font du recalage un problème très ouvert dans le domaine de la recherche et qui est étudié sous différents points de vue. Nous nous intéressons dans ce travail aux méthodes de recalage de l'approche

géométrique. Cette approche a l'avantage d'être précise, elle n'est pas contraignante du point de vue primitives, mais ne peut être utilisée dans tous les cas. Ce chapitre présente l'approche géométrique, son apport ainsi qu'un état de l'art sur l'ensemble des méthodes de cette approche. Nous abordons par la suite les limites communes entre ces dernières qui nous ont motivé à traiter cette problématique.

## 2.2 Recalage géométrique

Le recalage est un thème de recherche fondamental en traitement d'images. Il indique une méthode de mise en correspondance de deux images. La définition générale du recalage d'image pourrait être «une méthode visant à trouver la transformation géométrique qui aligne au mieux les pixels physiquement homologues de deux images » [Li, 2021][D'IMAGES, 2018]. C'est un processus qui permet de superposer la plus grande partie commune entre deux images. De manière un peu plus précise, il consiste à établir la relation entre les objets représentés par deux images. Il s'agit, en fait de trouver la transformation optimale qui est appliquée à une des images que nous appellerons image référence, permet de la rendre en correspondance avec l'autre image que nous appellerons image source. Nous nous intéressons par la mise en correspondance spatiale où les transformations géométriques sont mises en jeu dans le processus d'alignement.

### 2.2.1 Techniques de recalage

Faire un état de l'art sur les techniques de recalage, c'est s'attaquer à l'un des défis du traitement d'images. La pléthore des approches ainsi que des inspirations dans ce cadre de travail, due en partie à la relative absence de comparaison entre algorithmes, peut être compliquée. L'auteur *Lisa* concède que

"The diversity in problems and their applications has been the cause for the development of enumerable independent registration methodologies. This broad spectrum of methodologies makes it difficult to classify and compare techniques since each technique is often design for specific applications ... " [Brown, 1992]

ce qui explique l'apparition d'états de l'art plus spécifiques au problème traité, dans des revues plus généralistes, comme celle de [Frangi *et al.*, 2001]. Ce constat est d'autant plus terrifiant qu'il date de 1992, antérieurement à de nombreuses avancées apparues depuis, dont la plus représentative est sûrement l'introduction de considérations provenant de la théorie de l'information dans les mesures de similarité, initiée par [Loucif et Tighuiouart, 2019] et [West *et al.*, 1997]. Plus récemment, dans son état de l'art tout aussi connu dans le domaine [Maintz et Viergever, 1998], l'auteur fait appel au minimum à neuf axes orthogonaux pour classer les algorithmes de recalage, et présente un nombre important de références bien que se limitant au domaine médical. Nous sommes bien en face d'un thème de recherche très général, et regroupant beaucoup de méthodes ayant parfois peu points en commun.

Nous considérons cinq critères pour la classification des techniques de recalage dépendant de l'application visée :

- **La modalité** : Comment l'image est élaborée ? La modalité d'une image dépend du système d'acquisition,
  - **Les primitives** : Sur quel type d'information se fonde le recalage,
  - **Le critère de similarité** : Comment estimer l'appariement entre les points des images,
  - **Le modèle de transformation** : Comment les primitives sont alignées d'une image source à une image transformée,
  - **La stratégie d'optimisation** : Comment converger vers une solution rapidement
- Nous détaillons dans ce qui suit les cinq points.

### 2.2.2 Classification selon la modalité

La modalité d'une image correspond à la façon dont l'image a été élaborée, et aux moyens techniques, au matériel d'acquisition mis en œuvre [Chen *et al.*, 2021]. Il existe différentes manières pour présenter la vérité terrain à travers des modalités. L'imagerie médicale, en particulier, compte de nombreuses modalités telles que [Chen *et al.*, 2021] le scanner-X, l'imagerie par résonance magnétique (IRM), la tomographie par émission de positrons (TEP) [Zimmermann, 2021], la tomographie par mission de Mono-Photonique (TEMP) [Papathanassiou *et al.*, 2009], l'imagerie par ultrasons [Correas et Pol, 2012].

Certaines modalités comme le scanner ou l'IRM mettent en évidence des caractéristiques structurelles [Boustia *et al.*, 2019], alors que des modalités comme TEP ou TEMP montrent des informations fonctionnelles (débit sanguin) [Salaün *et al.*, 2019]. Le domaine de l'imagerie médicale illustre très bien les nécessités de recalage des images de modalités différentes afin d'obtenir une meilleure représentation ou compréhension de l'image. Il en est de même pour le domaine de l'imagerie spatiale ; les plus connus sont : le système RADAR est un instrument incontournable de télémétrie active et trouve des applications en topographie [Höfle et Pfeifer, 2007] et le système RADAR qui génère des modèles numériques d'altitude ou des cartes de déformation de la croûte terrestre [Rosen *et al.*, 2000][Massonnet et Feigl, 1998][Zebker, 2000][Bürgmann *et al.*, 2000].

Nous distinguons quatre types de recalage basé sur la modalité :

- **Recalage mono-modal** : Le recalage monomodal ne fait appel qu'à une seule modalité. Il est considéré comme relativement simple, car l'information commune aux images est très semblable d'une image à l'autre ; les niveaux de gris sont souvent comparables. Par exemple, il est souvent entrepris de faire de la détection de changement à partir d'acquisitions mono-modales. Il serait aisé de se contenter de cette vue des choses concernant le recalage, mais le recalage sur les seuls niveaux de gris n'est pas toujours aussi performant [Radouan *et al.*, 2020].

Les figures 2.1 et 2.2 montrent un exemple de recalage mono-modal pour les deux types d'imagerie spatiale et médicale.

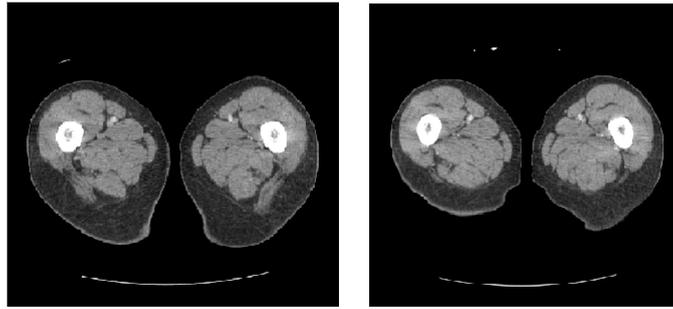


FIGURE 2.1 – Images mono-modale, Imagerie médicale (Scanner)

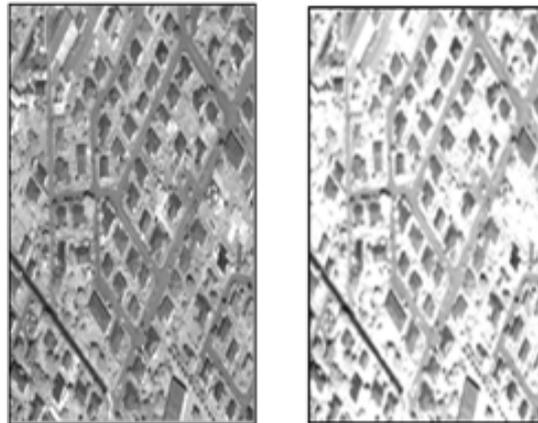


FIGURE 2.2 – Images monomodale, Imagerie spatiale (Satellite)

#### □ Recalage multimodal :

Le recalage multimodal regroupe plusieurs modalités à traiter, il concerne principalement la fusion d'informations anatomo-fonctionnelles provenant de diverses modalités, avec des structures (textures) complémentaires [thi, 1996]. La conception d'un système de recalage multimodal entre des données issues de modalités différentes est un problème complexe, difficilement optimal de par la différence entre la nature physique des images [Roche *et al.*, 2000].

La figure 2.3 illustre une paire d'images de modalités différentes. Le contenu des objets se révèle différent étant donné que les capteurs utilisés ne sont pas les mêmes, ainsi que la résolution, l'alignement et la texture des objets identifiés dans les deux images s'avèrent différents.

### 2.2.3 Classification selon les primitives

Le recalage d'images, nécessite la prise d'une décision par rapport au type de l'information à extraire et qui, est attachée aux pixels, pour permettre le suivi de leurs évolutions.

L'information fournie par les images peut paraître simple : c'est la valeur en ce pixel, autrement dit la grandeur physique mesurée par la modalité de l'image dans un petit volume autour du pixel, qui nous permettra de le suivre au cours de son mouvement. Si cette grandeur physique se conserve au cours du mouvement, il suffit alors d'apparier les pixels qui ont la même intensité.

Une question très importante qui se pose dans ce contexte ; *Les approches de recalage*

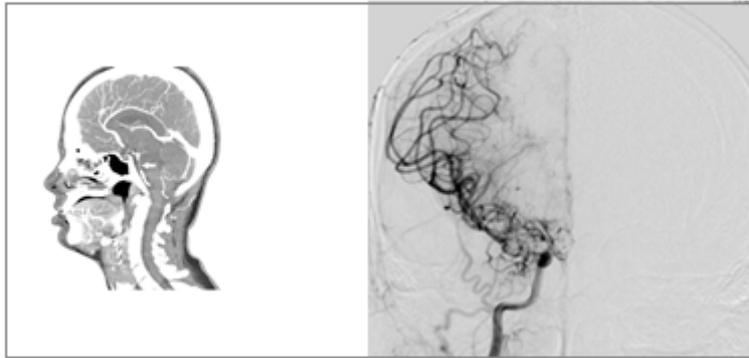
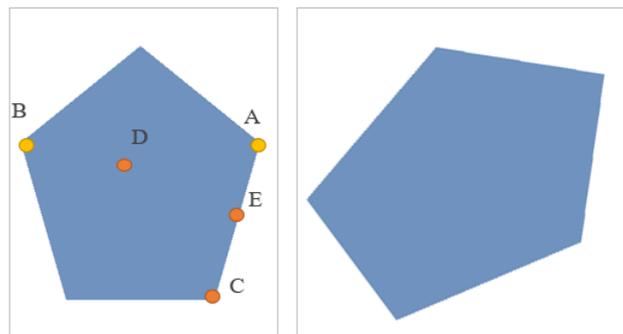


FIGURE 2.3 – Images multimodal (IRM (2D) / CT (2D))

### *géométrique sont elles naturelles ?*

Un autre problème est mis en question ; quel raisonnement cognitif faisons-nous pour retrouver les déplacements ? Un exemple d'un problème artificiel présenté à la figure 2.4 , où une forme bleu, initialement dans une position donnée, se transforme en une autre forme en subissant une transformation géométrique.

FIGURE 2.4 – Schématisation d'un problème de recalage ; Comment retrouver les mouvements des points  $A, B, C, D, E$ 

La figure 2.4 présente deux objets une forme géométrique (image à gauche : image source) et l'image source transformée (image à droite). Les points  $A, B, C, D$  et  $E$  sont des points que nous cherchons à retrouver leurs correspondants dans l'image transformée en se basant sur le raisonnement cognitif.

$A, C$  et  $B$  présentent des points coin, Pour les retrouver dans la figure de droite, nous regardons d'abord tous les coins de cette forme, avant de sélectionner parmi ceux-ci lequel lui correspond le mieux.  $E$  est un point situé sur le bord de la forme. Pour retrouver sa position, nous regardons où se sont déplacés les coins qui l'encadrent, ici  $A$  et  $C$  ; puis nous interpolons ces déplacements à  $E$ , avec la contrainte que  $E$  reste bien sur le bord de l'objet.

Quant au point  $D$ , qui est situé sur la surface de la forme, l'analyse visuelle se base sur les coins ou les points des bords les plus proches, par exemple les points  $B, E$  et  $A$ , et tente d'interpoler ces déplacements à  $D$ .

Nous avons donc tendance à extraire des amers géométriques (coins, courbes, etc.) et à les apparier ensuite en fonction de leur attributs géométriques. Le facteur intensité peut jouer un rôle important pour la détection du point si un appariement est mauvais ; mais des intensités

qui se correspondent ne confirment pas le bon appariement.

Comme nous venons de voir, l'approche géométrique est celle qui semble la plus naturelle. Elle consiste à extraire à partir des images un sous-ensemble de points caractérisés par une configuration géométrique significatif les distinguant des autres points. C'est cette décimation qui est porteuse de l'information cherchée. D'une manière générale, plus le critère géométrique de décimation est restrictif, plus l'appariement des amers géométriques avec leurs homologues pourront être considérés comme confirmé, et moins ces amers sont nombreux.

Toute la subtilité de l'approche géométrique consiste donc à sélectionner les bons amers, afin que ceux-ci soient suffisamment informatifs pour être recalés faiblement, et de manière contradictoire, suffisamment nombreux pour que l'interpolation du mouvement aux autres points soit également fiable.

#### 2.2.4 Classification selon le critère de similarité

Ce type de classification se repose sur un indice de similarité [Journet *et al.*, 2008].

Notons  $E$  un ensemble des individus à classer. Soit  $C$  le cardinal de  $E$  et  $x_j$  un élément quelconque de  $E$ . Soit  $A$  le nombre d'attributs. Nous supposons que les attributs sont présentés par les deux valeurs "0" ou "1";

- La valeur "1" correspond au cas où l'individu  $x$  possède l'attribut.

-  $X_{i,j}$  est la valeur de l'attribut numéro  $i$  pour l'individu  $X_j$  sachant que  $1 \leq i \leq T$  [De La Vega, 1967].

L'indice de similarité  $s$  entre des objets doit satisfaire les propriétés suivantes pour tout  $i, j, k \in 1, \dots, n$  :

$$— 0 < s(i, j) \leq 1;$$

$$— s(i, j) = s(j, i);$$

$$— s(i, i) = 1.$$

Une distance peut se transformer en similarité en posant

$$s(ij) = \frac{1}{1 + d(i, j)} \quad (2.1)$$

En fait, l'indice de similarité dépend du(des) type(s) de variables utilisées dans l'analyse (paramètres du recalage).

L'intérêt principal de cet indice de similarité est de sélectionner une partition de  $E$  qui se ressemblent sur la base d'un ensemble de critères envisagés. Il s'agit d'une classification selon le critère de similarité [Journet *et al.*, 2008].

#### 2.2.5 Processus du système du recalage géométrique

Le processus du recalage est composé de trois phases principales ; la détection, la description et la mise en correspondance des primitives.

De ce fait, les primitives constituent le point clé pour garantir un recalage performant en terme de précision.

Il existe trois types d'appariements possibles issus de la phase de la mise en correspondance des primitives :

- Les bons appariements : appelées inliers, déterminent la qualité et la précision de mise en correspondance d'une méthode.
- Les mauvais appariements : appelés outliers, détériorent les performances d'un processus de recalage. Parmi les types d'outliers on trouve les doublons qui correspondent à des points d'intérêt sélectionnés dans l'image décalée et qui ont la même trace dans l'image de référence. Un système de recalage doit éviter ce type d'appariement qui dégrade la qualité du rendu de la phase de mise en correspondance.
- Les points qui ne s'apparient pas, sont généralement issus d'un processus cherchant à diminuer les outliers. Ils ont l'avantage de ne pas pénaliser le système de recalage.

La sélection des emplacements des points d'intérêt et le choix de leur nombre constituent un compromis à accomplir lors de la conception d'un processus de recalage. Cet équilibre à déterminer constitue une des faiblesses du recalage géométrique. En effet, il faut mettre en place un mécanisme automatique de détection d'amers qui extrait une multitude de points fiables facilement repérés et minimise les faux amers qui brouillent la détermination de l'emplacement optimal.

## 2.3 Phases de recalage

L'étape d'appariement nécessite la définition d'un critère de similarité permettant de déterminer une certaine distance entre l'image de référence et l'image source. Ce critère est associé entre les deux ensembles d'amers des images à recalcr afin de trouver les attributs homologues. Il est basé sur la distance entre les primitives véritablement appariés. Il s'agit ensuite de ne garder que les couples d'amers homologues que l'on considère « inliers probables » relativement à des critères d'homogénéité avec leurs proches voisins.

### 2.3.1 Apport du recalage géométrique

Le recalage d'images établit une relation explicite entre des objets représentés dans deux images. Par objet, nous admettons un ensemble de points caractéristiques délimitant un contour, une surface, un volume, ou tout simplement, ne constituant qu'un point d'amer [Brown, 1992]. Le processus de recalage se réalise en deux étapes qui sont :

- 1- L'appariement des objets,
- 2- La recherche de la compatibilité entre les objets des deux images à recalcr.

L'approche du recalage d'image peut être vue sous trois angles distincts [thi, 1996], selon la variabilité de l'image :

- **Variabilité spatiale** : Induite par les changements de référentiels spatiaux liés à l'acquisition des images ;

- **Variabilité temporelle** : Cette variabilité est liée à l'évolution observée au cours du temps. C'est un problème récurrent qui peut se manifester par le déplacement, ou le changement d'orientation de rides de sable en fonction des courants. Nous parlons alors de recalage à long terme ; cela consiste à recaler des images dont les acquisitions diffèrent dans le temps.
- **Variabilité modale** : Liée à la nature des données exploitées qui dépend du système d'acquisition. Les contributions au recalage multi-modal sont de plus en plus répandues, surtout dans le domaine médical ou spatial.

### 2.3.2 Facteurs d'un système de recalage

Dans un système de recalage nous avons besoin de connaître des informations sur des facteurs considérés importants :

- La nature de la transformation géométrique nommée " $t$ " et son domaine de définition nommé " $T$ ",
- Le type de primitive utilisé (sur quoi porte  $t$ ),
- Le critère de similarité " $S$ ",
- La méthode d'optimisation.

Nous détaillons dans ce qui suit les différents types d'information extraites selon le recalage adopté.

#### 2.3.2.1 Extraction des primitives

Cette opération d'extraction des primitives est connue sous le nom de segmentation, qui consiste à extraire des points, des lignes ou des régions. La segmentation intervient pour fournir une représentation symbolique de l'image sous forme d'un ensemble de primitives, appelées aussi indices visuels.

Ces indices sont divers, allant du plus simple (le point) au plus complexe (contours, régions,) Le choix des éléments (ou primitives) image à mettre en correspondance est crucial. La primitive « idéale » est telle que ses propriétés intrinsèques permettent une mesure de ressemblance fortement discriminante [Pagoulatos *et al.*, 2000].

#### 2.3.2.2 Extraction des points d'intérêts

Un point d'intérêt correspond à un changement bidimensionnel du signal. Dans la littérature, les points d'intérêts ont été utilisés pour calculer la géométrie épi polaire, pour réaliser des appariements et pour effectuer les reconstructions 3D. A titre d'exemple, nous pouvons citer le détecteur de points d'intérêts le plus célèbre : le détecteur de Harris [Derpanis, 2004].

Ce détecteur a été proposé en considérant, seulement, les dérivées premières de l'intensité du niveau de gris pour calculer une fonction d'auto corrélation en tout pixel de l'image. L'existence d'un coin dans l'image se traduit par l'apparition de grandes valeurs propres lors de la diagonalisation de la matrice associée à sa fonction d'auto-corrélation.

### 2.3.2.3 Extraction des contours

Les contours représentent des zones de discontinuité de l'intensité lumineuse et ils sont représentés sous forme de suite de points connexes, de segments de droites ou de courbes. Les critères de ressemblance sont basés sur la forme ou sur la longueur et l'orientation des segments. Dans les images optiques, cette intensité est fonction de trois paramètres : l'intensité lumineuse incidente, le vecteur normal à l'élément de surface et la réflectance de l'élément de surface. Les contours correspondent à la discontinuité d'un ou de plusieurs de ces paramètres. Les caractéristiques d'un contour sont :

- **La continuité des points contours d'un objet** : Un contour est représenté par une chaîne connexe de points sur l'image. Il est possible de caractériser la forme des contours et d'utiliser des méthodes de reconnaissance de forme pour les comparer entre eux. L'utilisation du voisinage ou contexte d'un point contour donne des informations de forme et d'orientation.
- **L'épaisseur** : les contours représentent les frontières des objets. Il est important d'évaluer avec précision la position du contour de l'objet et de la représenter par un seul pixel qui correspond à la zone de variation maximale de la luminance.
- **La direction du contour est orthogonale à celle du gradient** : Le contour est caractérisé par le fait que la variation de luminance lui est perpendiculaire.
- **La robustesse au bruit** : Il faut débruiter l'image afin d'obtenir un contour aussi proche que possible de la réalité.

Pour obtenir à partir d'images souvent bruitées, des contours correspondant à ces caractéristiques, les algorithmes de segmentation en contours comprennent plusieurs étapes qui peuvent être confondues lors de l'implémentation :

- **Étape 1** : Filtrage des images afin d'atténuer l'influence du bruit ;
- **Étape 2** : Détection de contours : extraction d'un ensemble de points présentant les caractéristiques d'un contour ;
- **Étape 3** : Localisation des contours à partir de l'ensemble précédent, détermination de la position du contour et élimination des faux contours ;
- **Étape 4** : Chaînage des points contours.

### 2.3.2.4 Extraction des régions

Les régions sont caractérisées par leurs propriétés d'homogénéité généralement basées sur la luminance. Plusieurs approches de segmentation en régions ont été développées. Une synthèse de ces méthodes a été présentée dans [ZAGROUBA et DHIAF, ] :

- Croissance de régions (ou agrégation des pixels) qui regroupe progressivement les pixels de l'image avec leurs voisins en fonction de critères d'homogénéité. Les limitations inhérentes à cette méthode résident dans l'initialisation des germes et l'évolution du processus de croissance. La procédure de croissance peut être stabilisée par la superposition d'une carte de contours qui ralentit localement le processus de fusion des régions (deux régions ne peuvent être fusionnées si un contour trop abrupt les sépare).

- Division récursive de l'image et ceci en considérant initialement toute l'image comme une seule zone, un processus de division est appliqué récursivement sur chaque nouvelle zone qui ne satisfait pas un critère d'homogénéité. A l'arrêt de cette étape, toutes les régions sont homogènes. A ce processus peut s'ajouter un lissage par fusion des régions assimilées (en fonction de leur contexte) à un bruit. Cette technique est en fait pilotée par la mise en correspondance, le but étant de produire deux segmentations en régions aussi similaires que possible [Zucker, 1976].
- Split and Merge (division-fusion) : c'est une approche hybride qui procède par éclatement et regroupement de composantes de l'image. Pour raffiner le résultat de la division récursive de l'image, les couples des régions voisines issues de cette division sans contour commun et dont la réunion forme une zone homogène sont fusionnées. Afin d'éliminer les petites régions non significatives et les légères déviations sur les frontières des régions, un système de règles fondé sur la détection de contour est appliqué [Zhang, 1993].
- Approche hiérarchique par seuillage adaptatif des histogrammes : la première étape de cet algorithme consiste en appliquant une détection de contours. Tandis que la deuxième consiste en appliquant une segmentation de toutes les régions divisibles d'une manière récursive via la détermination automatique du seuil adaptatif et la vérification d'un critère de terminaison par les régions feuilles [Pestova, 2018].

## 2.4 Méthodes de recalage géométrique

Ce type d'approche est basé sur l'extraction de primitives à partir de chacune des images (i.e., points saillants, coins, contours, ...).

Par la suite, ces primitives sont appariées afin de déterminer la transformation entre les deux images. Cette approche est intéressante car ces primitives sont faciles à manipuler et elles sont indépendante des modalités. Cependant, extraire ces attributs pose souvent des difficultés [Menasria et Bennia, 2018] [Li, 2021]

### 2.4.1 Méthode SIFT (Scale-Invariant Feature Transform)

Le Scale-Invariant Feature Transform, SIFT, est un algorithme utilisé pour détecter et identifier les éléments similaires entre les différentes images numériques (éléments de paysages, objets, personnes). L'étape fondamentale de la méthode consiste à calculer les « descripteurs SIFT » des images à étudier. Il s'agit des informations numériques dérivées de l'analyse locale d'une image et qui caractérisent le contenu visuel de cette image de la façon la plus indépendante possible de l'échelle (« zoom » et résolution du capteur), du cadrage, de l'angle d'observation et de l'exposition (luminosité) [Ng et Henikoff, 2003].

L'algorithme SIFT est performant par rapport aux autres descripteurs dans le cas d'images texturées ou structurées ayant subi un changement d'échelle d'un ratio compris entre 2 à 2,5 ou une rotation comprise entre 30 et 45 degrés mais il n'est adapté à tous les types des images.

### 2.4.2 Méthode SURF (Speed Up Robust Feature)

Le Speeded Up Robust Features (SURF) est un algorithme de détection de caractéristiques, présenté par [Bay *et al.*, 2006]. Le SURF est fondé sur des sommes de réponses d'ondelettes de Haar 2D. N'étant que caractéristique de base, le SURF utilise une approximation d'ondelettes de Haar du détecteur de blob à base de déterminant hessien. Ces ondelettes permettent de calculer les dérivées premières de l'image sur un voisinage carré et d'étudier ainsi la répartition des gradients horizontaux et verticaux. Les réponses des ondelettes permettent ainsi de tracer le graphique de distribution des gradients et d'en déduire l'angle de recalage [Lowe, 2004]. Les points d'intérêt détectés par l'algorithme SURF sont facilement repérés et fiables ; mais leur nombre est très réduit et empêche parfois la caractérisation du modèle de transformation.

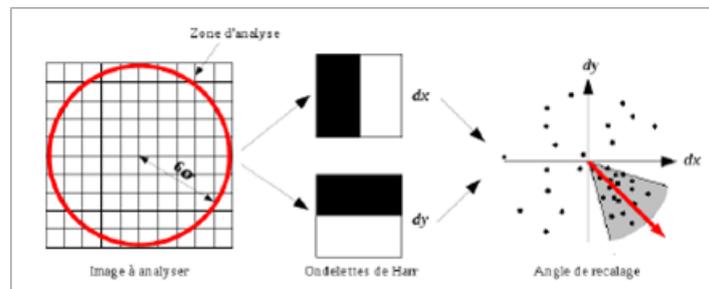


FIGURE 2.5 – Détermination de l'angle de recalage de l'algorithme SURF, en analysant la répartition des réponses des ondelettes de Haar [Bay *et al.*, 2006]

### 2.4.3 Méthode BRIEF (Binary Robust Independent Elementary Features)

L'algorithme Binary Robust Independent Elementary Features (BRIEF) est un algorithme de détection de caractéristiques, qui utilise un descripteur de point polyvalent qui peut être combiné avec des détecteurs arbitraires. Cet algorithme est utilisé pour la reconnaissance d'objet et la récupération d'image. En fait, la première étape consiste à créer un patch centré sur le point caractéristique, par la suite appliquer un filtre gaussien sur le patch obtenu, après la comparaison des deux intensités de pixels dans le patch des deux images, finalement générer une chaîne binaire de longueur  $n$ , cette chaîne correspond au le descripteur BRIEF [Calonder *et al.*, 2010].

L'algorithme BRIEF permet la combinaison de la détection des points-clés de l'espace-échelle de type SIFT et du descripteur de type BRIEF avec des échelles invariantes de rotation.

Il présente l'avantage de possibilité de traitement à haute vitesse avec la consommation de peu d'espace mémoire en plus, il n'est pas sensible à l'illumination et au changement de flou.

Néanmoins, il présente des inconvénients qui se réfèrent à sa sensibilité à la rotation du point de vue, et au changement de la position d'une source lumineuse.

### 2.4.4 Méthode ORB (Rotated BRIEF)

L'algorithme ORB est une fusion du détecteur de points d'intérêt nommé FAST et du descripteur BRIEF avec quelques modifications [Mikolajczyk *et Schmid*, 2005].

Initialement, pour déterminer les points d'intérêt, il utilise FAST. Ensuite, une mesure de coin *Harris* est appliquée pour trouver les  $N$  points supérieurs. L'algorithme FAST ne calcule

pas l'orientation et est une variante de rotation. Il calcule le centroïde pondéré en intensité du point d'intérêt avec le coin situé au centre. La direction du vecteur de ce point d'angle au centroïde donne l'orientation. Les moments sont calculés pour améliorer l'invariance de rotation. Le descripteur BRIEF ne fonctionne pas convenablement s'il y a une rotation dans le plan. Pour l'algorithme ORB, une matrice de rotation est calculée en utilisant l'orientation du patch et ensuite les descripteurs BRIEF sont orientés en fonction de la direction.

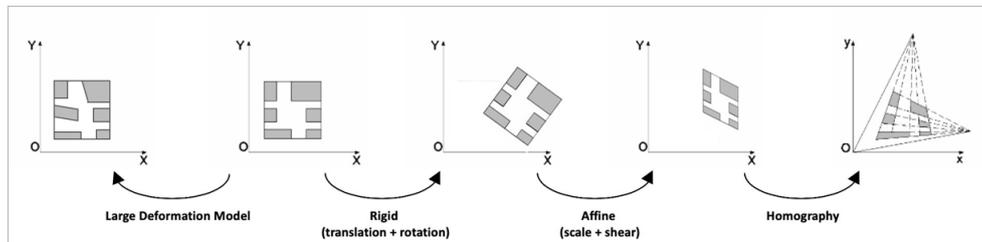


FIGURE 2.6 – Principe de l'approche [Mikolajczyk et Schmid, 2005]

#### 2.4.5 Méthode BRISK (Binary Robust Invariant Scalable Keypoints)

L'algorithme BRISK [Salaün *et al.*, 2019] est un détecteur de points d'intérêt et descripteur inspiré par AGAST [Agrawal *et al.*, 2008] et BRIEF [Mikolajczyk et Schmid, 2005]. Pour détecter les fonctionnalités, il utilise AGAST qui est l'amélioration de FAST en vitesse tout en conservant les mêmes performances de détection. Pour atteindre l'invariance d'échelle, il détecte les points d'intérêt dans une échelle pyramidale, effectuant la suppression non-maxima et une interpolation à toutes les échelles. Au lieu d'utiliser un modèle aléatoire comme dans BRIEF et ORB, les auteurs ont utilisé un motif symétrique pour décrire les caractéristiques. Ils ont utilisé plusieurs comparaisons de points d'échantillonnage à grande distance pour déterminer orientation et pour la comparaison à longue distance du vecteur le déplacement entre les points d'échantillonnage est stocké et pondérée par la différence relative d'intensité. Ensuite, pour déterminer la direction du gradient dominant de patch ces les vecteurs pondérés sont moyennés.

#### 2.4.6 Méthode FREAK (Fast Retina Keypoint)

Le FREAK [Ambai et Yoshida, 2011] (Fast Retina Keypoint) est un descripteur inspiré par le système visuel humain. Il fournit un descripteur avec l'orientation des caractéristiques en additionnant des gradients locaux sur des paires de points sélectionnées. Il utilise un modèle spécifique d'échantillonnage ponctuel qui permet des économies en espace mémoire. Alors que le descripteur résultant est toujours une chaîne binaire comme pour l'algorithme BRIEF [Mikolajczyk et Schmid, 2005], le modèle d'échantillonnage permet l'utilisation d'une approche « grossière à fine » pour décrire les caractéristiques. Il compare en premier lieu les paires de points portant l'information sur les caractéristiques les plus distinctives du quartier caractéristique. Cela permet un rejet plus rapide des fausses correspondances et une optimisation de la complexité temporelle.

### 2.4.7 Méthode Corner

Le détecteur de coins (Corner detector) fonctionne en repérant les contours dans l'image avant d'extraire les points d'intérêt qui sont des points de courbures maximales et des intersections de contours. *Harris et Stephens* ont proposé un algorithme de détection de coin qui permet la détection des croisements de lignes. Après le rangement des coins détectés, une détection des maxima locaux est faite pour éliminer les coins trop proches [Derpanis, 2004]. La méthode Corner permet d'extraire une multitude de points d'intérêt dont le nombre est l'un des paramètres de cette méthode et généralement suffisant pour la caractérisation du modèle de transformation.

### 2.4.8 Méthode KAZE

L'algorithme KAZE [Alcantarilla *et al.*, 2012] est une présente une méthode de détection et de description de points d'intérêt dans une image. Cette méthode constitue une alternative plus fiable que d'autre méthodes de recalage géométrique telles que SIFT et SURF.

L'algorithme KAZE propose des méthodes de détection et de description des points d'intérêt réalisées dans un espace non linéaire permettant la préservation des contrastes locaux, ce qui améliore la détection, contrairement à des méthodes telles que SIFT où la recherche de l'invariance à l'échelle est réalisée dans un espace linéaire suite à la convolution d'images pyramidales avec un noyau gaussien.

D'après la littérature, la méthode KAZE permet de dépasser les méthodes SIFT et SURF et en terme de performance machine et en terme de résultats.

Le descripteur de la méthode KAZE est basé sur une modification de la méthode SURF, nommée M-SURF.

### 2.4.9 Méthode AKAZE (Accelerated KAZE Features)

L'algorithme AKAZE [Alcantarilla *et Solutions*, 2011] est la version accélérée de KAZE. Il est développé par les mêmes auteurs de KAZE. Ils ont proposé une amélioration de leurs propre méthode en introduisant le concept de FAST Explicit Diffusion qui permet de mieux gérer la non linéarité de la phase de détection. Et dans la description, les auteurs utilisent une modification de LDB (Local Difference Binary [Yang *et Cheng*, 2013]) afin d'accélérer les calculs. Bien que très rapide, la rapidité d'AKAZE n'entraîne pas de baisse de la qualité du recalage.

L'algorithme AKAZE permet d'obtenir des résultats plus fiable que les méthodes de description existantes.

## 2.5 Évaluation des méthodes de recalage géométrique

Les méthodes de recalage géométrique présentées dans la section précédente reposent sur deux phases importantes qui sont la phase de détection et de description des primitives. Ces derniers vont servir la phase de mise en correspondance qui possède un impact majeur sur la qualité du recalage.

Nous rappelons que toutes ces méthodes partagent le même type de base de connaissance qui est constituée par des informations au niveau pixelique (i.e., information issues du système

d'acquisition).

Nous avons défini un ensemble de critères d'évaluation de performance des méthodes de l'approche de recalage géométrique afin d'étudier l'influence des informations issues du capteur sur la qualité du recalage en termes de sensibilité au type de transformation, sensibilité aux bruits, nombre de faux important et précision du recalage performante.

Le Tableau 2.1 illustre le type du détecteur, le type du descripteur ainsi que l'évaluation des performances de chacune des méthodes de recalage de l'approche géométrique [Marzouka *et al.*, 2020b]. Ces critères de performances suivent l'ordonnement suivant :

TABLEAU 2.1 – Présentation des méthodes de recalage de l'approche géométrique

Méthodes	Descripteurs	Détecteurs	Critères de Performance (1)(2)(3)(4)
<b>SIFT</b>	Gradient	Log Pyramid	◆ ◆ ◆ ▼
<b>Surf</b>	Haar wavelets	Fast-Hessian	▼ ◆ ◆ ▼
<b>BRIEF</b>	BRIEF descriptor	N/A	▼ ◆ ◆ ▼
<b>BRISK</b>	BRIEF descriptor	AGAS	◆ ◆ ◆ ◆
<b>ORB</b>	BRIEF descriptor modifié	oFAST	◆ ◆ ◆ ▼
<b>FREAK</b>	FREAK descriptor	N/A	◆ ◆ ◆ ▼
<b>FREAK</b>	FREAK descriptor	N/A	◆ ◆ ◆ ▼
<b>KAZE</b>	M-SURF	Hessian	◆ ◆ ◆ ▼
<b>AKAZE</b>	MLDB	Hessian	◆ ◆ ◆ ▼

(1)-Sensibilité au type de transformation,

(2)- Sensibilité aux bruits,

(3)- Nombre de faux amers important,

(4)- Précision du recalage.

Et qui sont schématisées par les symboles suivants :

◆ : Indique l'efficacité du critère ;

◆ : Indique la limite du critère ;

▼ :Indique que le critère n'est pas entièrement validé.

Les résultats de l'évaluation des performances des méthodes de l'approche de recalage géométrique prouvent que ces derniers souffrent de deux problèmes majeurs qui sont la sensibilité aux bruits (2) et le nombre important des faux amers (3). Cela est dû aux types des informations

considérées lors de la détection des primitives qui sont des informations au niveau pixelique. Quant aux critères de performance (1) et (4), ils varient selon la méthode de recalage et ne dépendent pas du type de la base de connaissances.

Pour remédier à ces limites nous proposons de passer du **niveau pixelique** de représentation des informations à un niveau de représentation basé sur le contenu sémantique des images à recalage appelée **niveau sémantique**. Ce dernier permet d'avoir une base de connaissances plus riche en informations qui ne dépend pas du système d'acquisition.

## 2.6 Conclusion

Dans ce chapitre nous avons présenté un état de l'art sur les méthodes de recalage. Nous sommes concentrés sur les méthodes de recalage géométrique ; il existe des divers méthodes de recalages qui souffrent du problème du nombre important de faux amers. Nous avons présenté aussi une étude comparative des méthodes existantes afin de dégager les limites de ces derniers.

Nous présentons dans le chapitre suivant, les fondements de base de l'approche proposée ainsi que les contributions.

# ESTIMATION DES DISTRIBUTIONS DES POSSIBILITES POUR LE RECALAGE GEOMETRIQUE

---

## Sommaire

---

<b>3.1</b>	<b>Introduction</b> . . . . .	<b>41</b>
<b>3.2</b>	<b>Fondements de base</b> . . . . .	<b>42</b>
<b>3.3</b>	<b>Caractéristiques de l’information</b> . . . . .	<b>42</b>
3.3.1	Donnée, information et connaissance . . . . .	42
3.3.2	Sources d’information . . . . .	42
3.3.2.1	Représentations des informations . . . . .	43
3.3.3	Qualité de l’information . . . . .	44
<b>3.4</b>	<b>Imperfections de l’information</b> . . . . .	<b>45</b>
<b>3.5</b>	<b>Représentations numériques de connaissances imparfaites</b> . . . . .	<b>46</b>
3.5.1	La théorie des probabilités . . . . .	47
3.5.2	La théorie de l’évidence ou de croyance . . . . .	47
3.5.3	La théorie des ensembles flous . . . . .	47
3.5.4	La théorie des possibilités . . . . .	47
<b>3.6</b>	<b>Fondements de la théorie des possibilités</b> . . . . .	<b>48</b>
3.6.1	Principe de base . . . . .	48
3.6.2	Concepts de base de la théorie des sous-ensembles flous . . . . .	48
3.6.2.1	Définition de la théorie des sous-ensembles flous . . . . .	48
3.6.2.2	Caractéristiques d’un sous-ensemble flou . . . . .	49
3.6.2.3	Éléments de base de la théorie des possibilités . . . . .	49
3.6.2.4	Fondement mathématique de la théorie des possibilités . . . . .	51
<b>3.7</b>	<b>Approche de recalage basée sur une projection sémantique</b> . . . . .	<b>52</b>
<b>3.8</b>	<b>Projection sémantique supervisée</b> . . . . .	<b>54</b>
3.8.1	Présentation . . . . .	54
3.8.2	Méthodes de classification supervisée existantes . . . . .	55
3.8.2.1	Les approches discriminantes . . . . .	55
3.8.2.2	Les approches génératives . . . . .	56
3.8.3	Études comparatives des méthodes existantes . . . . .	57
3.8.4	Méthode proposée . . . . .	57

<b>3.9</b>	<b>Projection sémantique non supervisée</b>	<b>58</b>
3.9.1	Méthodes de clustering existantes	59
3.9.1.1	Classification hiérarchique	59
3.9.1.2	Classification par regroupement	59
3.9.1.3	Méthode de classification C-Moyennes-Floues (FCM)	60
3.9.1.4	Clustering multi-centroïdes basé sur le FCM	61
3.9.2	Méthode proposée	61
<b>3.10</b>	<b>Génération des cartes de possibilité</b>	<b>61</b>
3.10.1	Contexte supervisé	62
3.10.1.1	Apprentissage	62
3.10.1.2	Modélisation de l'approche	62
3.10.1.3	Calcul des distributions de possibilités	62
3.10.2	Contexte non supervisé	63
3.10.2.1	Indice de validité de clustering flou	64
3.10.2.2	Phase de l'estimation	66
3.10.2.3	Méthode pour l'estimation de la fonction de masse	66
3.10.2.4	Estimation de la distribution de masse	67
<b>3.11</b>	<b>Conclusion</b>	<b>68</b>

## 3.1 Introduction

Nous avons pu montrer à travers l'évaluation de la performance des méthodes de l'approche géométrique que les limites de cette dernière proviennent de l'imperfection des informations issues des images à recalcer.

Dans ce chapitre, nous mettons l'accent sur l'information, sa définition et ses caractéristiques. Ainsi, nous présentons la différence entre les notions de base; information, connaissance et donnée.

Dans ce contexte, nous exposons un état de l'art sur les fondements de base des théories d'incertitudes pour étudier l'imperfection des informations afin de montrer leurs apports pour la création d'une base de connaissances contenant des informations certaines afin d'avoir un résultat de recalage fiable. Par la suite, nous allons présenter une contribution de notre travail qui consistait en l'exploitation de la théorie de possibilité pour la création de la nouvelle base.

Deux contextes se présentent; un contexte supervisé qui est basé sur des informations sûres (les classes de l'image) fournis par un expert et un contexte non supervisé nécessitant un traitement pour l'obtention des classes des images à recalcer.

Nous mettons l'accent particulièrement sur la théorie des possibilités puisque nous l'adaptions comme l'outil principal pour la création du nouvel espace de représentation des connaissances.

## 3.2 Fondements de base

Nous distinguons différents types d'imperfections qui accompagnent les informations telles l'imprécision, l'incertitude, le conflit... La présence d'une information imparfaite dans un processus de recalage est inévitable et causée principalement le processus de l'acquisition. C'est pour cela qu'il est important de prendre en considération la possibilité d'avoir des informations imparfaites, et d'assurer un processus de gestion des incertitudes pour garantir la fiabilité du résultat final. Nous définissons dans ce qui suit les différentes notions afin de bien étudier leurs causes.

## 3.3 Caractéristiques de l'information

Dans cette section nous mettons l'accent sur les différentes notions et terminologies liées à l'analyse et l'interprétation de l'information.

### 3.3.1 Donnée, information et connaissance

Données, information et connaissance sont, souvent, utilisées dans l'analyse et le traitement de l'information mais avec une grande confusion et ambiguïté. Il est important de soulever ce problème pour distinguer la différence et la relation entre ces termes . Ces trois concepts présentent trois niveaux d'abstractions ayant une relation hiérarchique ascendante qui commence des données vers les connaissances. Le passage d'un niveau d'abstraction à un autre se fait à travers des techniques bien déterminées.

- Donnée : Désigne l'état brut qui peut être un signal ou une longueur d'onde provenant d'un instrument physique tels que : les caméras, les capteurs, les séismogrammes. Les données sont des entités ou des mesures représentées sous forme de valeurs. Les données dans leurs états bruts ne portent pas une signification ambiguë.
- Information :Elle résulte de la procédure de traitement des données brutes qui cherche les adapter au mieux dans un contexte informatif. Elle peut avoir plusieurs formes complexes telles que : vidéo, audio, et image.
- Connaissance :Représente le troisième niveau d'abstraction. Elle peut être vue en tant qu'une compréhension du phénomène observé. Elle résulte du traitement,de l'apprentissage et de l'évaluation de l'information.

### 3.3.2 Sources d'information

Nous distinguons différentes sources d'informations ; un capteur, un satellite, une image, une base de données ou un expert qui fournit des informations. Une source peut être caractérisée par ses qualités sur lesquelles se basent les étapes de traitements des informations qui suivent. En effet, une source peut être soit *objective* soit *subjective*. Les informations provenant d'une source *subjective* sont exprimées sous une forme non numérique tels qu'une description linguistique ou un intervalle de valeurs (par exemple : {Grand, petit,...}). Ainsi, les experts et les observateurs

sont les principales sources *subjectives* puisqu'ils expriment les informations sous forme d'observations, d'hypothèses, et de croyances. En revanche, les capteurs, les satellites et les instruments électroniques appartiennent à la famille des sources objectives.

Les deux catégories de source, objective et subjective sont caractérisées par leurs *fiabilité* et leurs *pertinence* [Bloch *et al.*, 2001]. La fiabilité traduit la crédibilité de la source et la sûreté des informations fournies. Cette caractéristique est souvent exprimée à travers un coefficient de fiabilité qui est généralement déterminé empiriquement ou par des méthodes de raisonnement adaptées au contexte [Martin *et al.*, 2008, Bloch, 2008, Bloch et Maître, 2004]. Le degré de fiabilité d'une source subjective traduit la confiance en cette source [Rogova et Bosse, 2010].

Selon [Pichon *et al.*, 2012] la fiabilité d'une source remet en cause deux caractéristiques importantes ; la pertinence et la crédibilité. La pertinence de la source décrit à quel point la source fournit des informations importantes et qui concernent le sujet d'étude. En revanche, une source est crédible si elle fournit la totalité de ses informations.

### 3.3.2.1 Représentations des informations

Étant donnée une source d'information  $I$ , les informations qu'elle fournit forment l'ensemble des observations (comme, par exemples : niveaux de gris, fréquences...) :  $X = \{x_1, \dots, x_n\}$  avec  $n$  la cardinalité de l'ensemble  $X$ . Les  $x_i$  sont les valeurs qui représentent le problème étudié. Ces informations portent sur un ensemble qu'on note  $\Omega$  qui est , appelé *ensemble de définition de l'information* dont les éléments représentent les hypothèses qui modélisent les informations (classes, modèles...). L'ensemble de définition de l'information se caractérise principalement par deux notions mathématiques qui sont *l'exhaustivité* et *l'exclusivité* :

- L'ensemble  $\Omega$  est dit exhaustif s'il contient toutes les hypothèses qui représentent le problème abordé. Autrement dit, chaque observation  $x_i$ ,  $i = 1, \dots, n$  est représentée par l'un des éléments de  $\Omega$ . Ce phénomène est décrit par le raisonnement sous la condition du monde fermé.
- L'ensemble  $\Omega$  est dit exclusif si l'observation  $x_i$  de l'ensemble  $X$ , est représentée par un seul élément de cet ensemble.

L'association d'une information de  $X$  à un élément de  $\Omega$  se fait à l'aide des fondements mathématique (i.e. via une fonction). Inversement, un élément de l'ensemble de définition peut être caractérisé par un ou plusieurs observations de l'ensemble  $X$ . Cependant, dans certaines situations la fonction mathématique ne permet pas de déterminer avec certitude l'élément exacte de  $\Omega$  qui correspond à  $x_i$  même si  $\Omega$  est exhaustif ou exclusif. En effet, c'est le résultat de la qualité et les caractéristiques de l'information traitée. Plus précisément, une information est dite imparfaite s'il n'est pas possible de déterminer avec certitude son élément correspondant dans l'ensemble  $\Omega$ .

La figure 3.1 illustre un schéma simplifié du processus de l'association des éléments de  $X$  à ceux de  $\Omega$ .

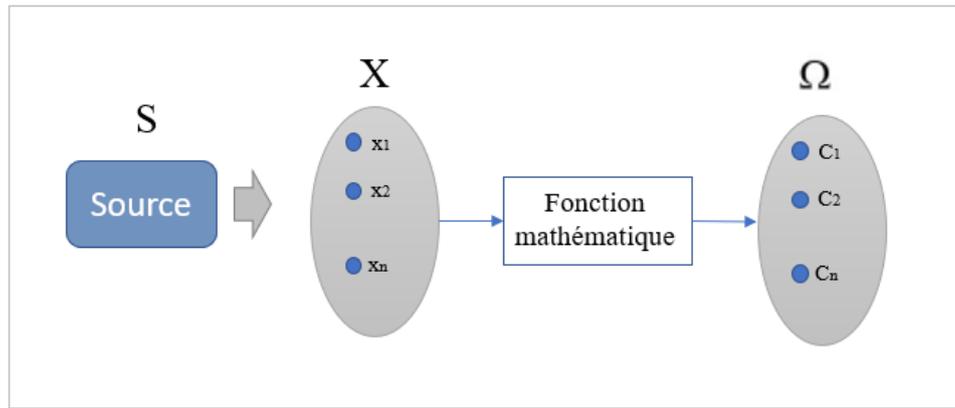


FIGURE 3.1 – Affectation des informations à l’ensemble des hypothèses

### 3.3.3 Qualité de l’information

La *Qualité de l’Information*,  $QI$ , a été définie en tant qu’une mesure dans laquelle les informations ont des caractéristiques, du contenu, de forme et de temps, qui leur donnent une valeur [O’Brien, 2000]. Dans un système de traitement d’information que ce soit mono ou multi sources, il est important de tenir compte de la qualité de l’information pour avoir un traitement ainsi qu’une interprétation meilleurs.

Pour estimer, la qualité de l’information, il faut identifier ses différents attributs et critères qui sont des fois spécifiques à l’utilisateur et/ou l’expert [Rogova et Bosse, 2010, Harrathi et Calabretto, 2006]. La littérature propose plusieurs taxonomies des attributs de la qualité de l’information. L’une parmi les plus citées est celle de [Wang et Strong, 1996] où les auteurs estiment que les attributs englobent les aspects suivants ; l’intrinsèque, le contextuelle, le représentatif, et l’accessibilité de l’information [Todoran, 2014].

Une autre classification des attributs de la qualité de l’information où les auteurs indiquent trois grandes catégories de la qualité dans un système de fusion qui sont : la qualité de la source d’information, la qualité du contenu de l’information et la qualité de la représentation de l’information [Rogova et Bosse, 2010].

Le Tableau 3.1 résume les différents attributs pour chaque catégorie :

Les différents attributs gravitent autour de ces critères qui affectent le degré de confiance à une source utilisée dans le traitement.

Par ailleurs, les attributs relatifs à la qualité du contenu de l’information et qui sont principalement au nombre de cinq peuvent révéler à quel point il est intéressant de considérer cette information.

- **Pertinence** : Il concerne l’utilité de l’information dans le processus de traitement d’information.
- **Obsolescence** : En anglais c’est “Timeliness”, cet attribut concerne l’utilité de l’information à l’instant où elle est devenue disponible. Ainsi, c’est une qualité temporelle.

TABLEAU 3.1 – Attributs de la qualité de l'information

Qualité de l'information		
Source d'information	Contenu d'information	Représentation d'information
Objectivité	Disponibilité	Compréhensibilité
Réputation	Obsolescence	Complétude
Crédibilité	Pertinence	Interprétabilité
Fiabilité	Accessibilité	Obsolescence
Pertinence	Complétude	
Véracité		
Niveau d'expertise		

- **Accessibilité et disponibilité** : Les informations doivent être accessibles facilement et disponibles quand l'expert veut les utiliser.
- **Complétude** : L'information doit être complète et permet de fournir des connaissances intégrales sur le sujet d'étude.

Le passage du niveau de données/informations à l'exploitation de l'information dans un système de prise de décision implique nécessairement une présentation particulière. Cette représentation doit garantir les quatre attributs de la qualité qui sont : **la compréhensibilité, la complétude, l'interprétabilité et l'obsolescence** afin d'obtenir une décision fiable.

Bien que l'information peut être décrite par ses qualités et ses différents attributs, elle est couramment manipulée dans des systèmes de traitement conjoint d'informations en tenant compte de ces différentes *imperfections*. Les notions liées à l'imperfection de l'information sont exposées dans la section suivante.

### 3.4 Imperfections de l'information

La plupart des méthodes de traitement de données ont été développées pour traiter des données numériques classiques, validées et complètes. Or en pratique, il s'agit le plus souvent d'informations attachées au monde réel (observations, mesures, connaissances génériques sur des phénomènes réels, etc.), et également au monde virtuel (expression des buts de l'utilisateur et de ses préférences). Dans le cadre de l'extraction de connaissances à partir de ces données, nous pouvons distinguer deux types d'imperfection à savoir l'imperfection au niveau valeur de données et l'imperfection au niveau association entre valeur. Le premier type existe quand on ne peut pas déterminer de façon précise la valeur que peut prendre un attribut. Le deuxième type d'imprécision existe dans l'association des valeurs de données. A noter que ces deux types d'imperfections peuvent coexister.

Les imperfections des informations manipulées se manifestent sous des formes multiples : ambiguïté, bruit, incomplétude, incohérence, conflit, imprécision et incertitude.

- L'incertitude est relative à la vérité d'une information et caractérise son degré de conformité à la réalité. Elle fait référence à la nature de l'objet ou du fait concerné, à sa qualité, à son essence ou à son occurrence.
- L'imprécision concerne le contenu de l'information et mesure donc un défaut quantitatif de connaissance. Elle concerne le manque d'exactitude en quantité, en taille, en durée. . .

L'imprécision est souvent confondue avec l'incertitude, car les deux types d'imperfection sont souvent présents simultanément, et l'un peut induire l'autre. Il est important de les distinguer car elles sont souvent opposées, même si ces deux termes peuvent être inclus dans une acception plus large de l'incertitude.

- L'incomplétude caractérise l'absence d'information apportée par la source sur certains aspects du problème. L'information fournie par une source est en général partielle, elle ne fournit qu'une vision du monde ou du phénomène observé, en n'en mettant en évidence que certaines caractéristiques.
- L'ambiguïté exprime la capacité d'une information de conduire à deux interprétations. Elle peut provenir des imperfections précédentes.

***Exemple :***

- ⊗ L'imprécision d'une mesure ne permet pas de différencier l'appartenance d'un objet à l'une de deux classes.
- ⊗ L'incomplétude qui induit des confusions possibles entre des objets et des situations qui ne peuvent être séparées selon les caractéristiques mises en évidence par la source.
  - Le conflit caractérise deux ou plusieurs informations conduisant à des interprétations contradictoires et donc incompatibles.
  - La redondance est la qualité de sources qui apportent plusieurs fois la même information. La redondance entre les sources est souvent observée, dans la mesure où les sources donnent des informations sur le même phénomène. Idéalement, la redondance est exploitée pour réduire les incertitudes et les imprécisions.
  - La complémentarité est la propriété des sources qui apportent des informations sur des grandeurs déférentes. Elle vient du fait qu'elles ne donnent en général pas d'informations sur les mêmes caractéristiques du phénomène observé. Elle est exploitée directement dans le processus de fusion pour avoir une information globale plus complète et pour lever les ambigüités.

### **3.5 Représentations numériques de connaissances imparfaites**

Les principales théories permettant de représenter des connaissances imparfaites sont :

- Les probabilités,
- Les fonctions de croyance,
- Les ensembles flous,
- Les possibilités.

Nous présentons dans ce qui suit une étude comparative entre ces différentes théories.

### 3.5.1 La théorie des probabilités

La théorie des probabilités est la plus ancienne et la plus exploitée. Elle trouve ses origines dans l'analyse de jeux de hasard par *Gerolamo Cardano* au 16<sup>ième</sup> siècle, et par *Pierre de Fermat* et *Blaise Pascal* au 17<sup>ième</sup> siècle. Elle modélise l'imprécision par une distribution de probabilités sur l'espace de définition. Elle fait la combinaison des valeurs issues de différentes sources en se basant sur la règle de *Bayes* qui nécessite la connaissance de la probabilité *a priori*.

Cette théorie présente des bases mathématiques solides et de nombreux outils permettant la modélisation ou l'apprentissage des modèles. Elle est considérée aussi comme étant un concept universel pouvant servir de base de comparaison pour les autres méthodes. Néanmoins, dans de nombreux problèmes, le calcul des probabilités est difficile vu la difficulté de modéliser le comportement des sources dépendantes et surtout la gestion des conflits. De plus, la théorie des probabilités n'est pas adaptée à la modélisation de la méconnaissance.

### 3.5.2 La théorie de l'évidence ou de croyance

Cette théorie est introduite par *Shafer* à la fin des années 70. Elle permet de représenter à la fois l'imprécision et l'incertitude de l'information. Elle effectue une modélisation basée sur une fonction, dite *masse de croyance*. Des notions de plausibilité et de crédibilité. La fonction de plausibilité fut introduite sous une hypothèse de monde fermé.

La crédibilité d'une source ou la confiance en une source quantifie la confiance que l'on peut porter à la source. Elle doit tenir compte de toutes les imperfections de la source. La mesure de crédibilité est un degré de confiance d'une source ou de la sortie d'un système de fusion.

La théorie de l'évidence est définie sur l'ensemble des sous-ensembles d'un univers de référence (i.e., généralisation des probabilités bayésiennes à des événements non exclusifs). Elle applique une combinaison des valeurs issues des différentes sources à l'aide de la *loi de Dempster*.

Cette théorie fournit une meilleure modélisation de méconnaissance, et gère les conflits. Néanmoins, elle ne dispose pas de cadre générique pour la modélisation de la connaissance et présente une difficulté dans l'interprétation des masses de croyance puisqu'elle ne possède pas de méthode universelle pour l'estimation des masses de croyance.

### 3.5.3 La théorie des ensembles flous

La théorie des ensembles flous développée par *Zadeh* dans au milieu des années 60 a progressé jusqu'au début des années 90. Elle permet une modélisation très souple des informations imprécises. Sur le plan mathématique, les ensembles flous sont représentés par des fonctions d'appartenance à un ensemble modélisant l'appartenance partielle d'un objet à une classe bien déterminée. Les fonctions d'appartenance permettent de représenter des distributions de possibilités dans le cas où les éléments du référentiel sont mutuellement exclusifs.

### 3.5.4 La théorie des possibilités

La théorie des possibilités introduite par *Zadeh* en 1978, puis développée par *Dubois* et *Prade* dans les années 80 est dérivée de la théorie des ensembles flous. Cette approche permet de repré-

senter à la fois les imprécisions et les incertitudes de l'information en utilisant les distributions de possibilité. Dans cette approche, toute la connaissance disponible est explicitement représentée par des distributions de possibilité. En d'autres termes, on considère des relations usuelles dans lesquelles certaines valeurs d'attributs peuvent être connues de façon imprécise.

Les distributions de possibilité apparaissent comme valeurs des attributs. Dans le cadre de la fusion d'informations la théorie des possibilités offre plusieurs intérêts. Elle dispose de nombreux opérateurs de combinaison pour faire la combinaison des valeurs issues de différentes sources. Parmi ceux-ci, on cite les opérateurs conjonctifs, disjonctifs ou adaptatifs. De plus, en utilisant cette théorie, la modélisation de la connaissance devient facile grâce aux fonctions de distributions de type trapèze ou triangulaires et de même la gestion du conflit par les règles adaptatives. Aussi, elle permet d'introduire différentes sémantiques, de tenir compte de l'information spatiale en traitement d'images et de combiner des informations très variées grâce à la richesse et la souplesse des opérateurs proposés. Mais, cette théorie présente une difficulté lors du choix du mode de combinaison le mieux adapté aux données. La théorie des possibilités diffère de la théorie des probabilités, surtout par le fait qu'il est possible de modéliser l'incertitude et l'ambiguïté, ce qui n'est pas le cas avec des probabilités.

Nous avons retenu la théorie des possibilités pour la modélisation du problème de recalage et nous détaillons ses fondements dans la section suivante.

## 3.6 Fondements de la théorie des possibilités

### 3.6.1 Principe de base

Étant donné un ensemble fini  $X$  de référence, chaque sous ensemble  $A$  de  $X$  est considéré comme un événement. Une mesure  $a$  attribuée  $A$  pour un objet  $x$  évalue à quel point cet événement  $A$  est possible pour l'objet  $x$ . Si la valeur  $a$  est connue avec précision, on peut déduire que  $A$  ne peut prendre pour  $x$  aucune valeur distincte de  $a$ . Néanmoins, la situation est différente lorsque la valeur  $a$  n'est pas connue avec précision. Nous connaissons par exemple seulement des distributions de possibilité restreignant les valeurs possibles de  $a$  pour un objet  $x$ . Ces mesures présentent une distribution de possibilité permettant d'attribuer un degré de possibilité à tout sous ensemble  $A$  de  $X$ . Dans ce cas, on ne peut pas déclarer qu'une affirmation concernant la valeur de cet objet est définitivement vraie ou définitivement fausse. Ainsi, Les mesures de possibilités sont l'une des familles de mesures floues proposées dans la littérature. Puisque la théorie des possibilités est déduite de la théorie des ensembles flous, nous ne pouvons pas en parler sans introduire les concepts de base de la théorie des ensembles flous. Par abus de langage, nous utilisons indifféremment les termes *sous-ensemble flou* et *ensemble flou*.

### 3.6.2 Concepts de base de la théorie des sous-ensembles flous

#### 3.6.2.1 Définition de la théorie des sous-ensembles flous

Soit un univers  $X$ . Un sous-ensemble flou  $A$  de  $X$  est défini par une fonction d'appartenance  $\mu_A(x) : X \rightarrow [0, 1]$  qui à chaque élément  $x$  de  $X$  associe une valeur de l'intervalle  $[0, 1]$ .

Cette valeur représente le degré d'appartenance de  $x$  au sous-ensemble flou  $A$ .

- Si  $\mu_A(x) = 0$  alors  $x$  n'appartient pas à  $A$ .
- Si  $\mu_A(x) = 1$  alors  $x$  appartient complètement à  $A$ .
- Si  $0 < \mu_A(x) < 1$  alors  $x$  appartient à  $A$  avec un degré  $\mu_A(x)$ .

### 3.6.2.2 Caractéristiques d'un sous-ensemble flou

Un sous-ensemble flou  $A$  de l'univers  $X$  possède les principales caractéristiques suivantes Figure 3.2.

- Support, noté  $\text{supp}(A)$ , qui représente une partie de  $X$  telle que la fonction d'appartenance de  $A$  n'est pas nulle :  $\text{supp}(A) = \{x \in X / \mu_A(x) \neq 0\}$
- Noyau, noté  $\text{noy}(A)$ , qui est l'ensemble des éléments de  $X$  pour lesquels la fonction  $\mu_A(x)$  vaut 1 :  $\text{noy}(A) = \{x \in X / \mu_A(x) = 1\}$
- Hauteur, notée  $h(A)$ , qui représente la plus grande valeur prise par sa fonction d'appartenance  $\mu_A(x)$  :  $h(A) = \sup_{x \in X} \mu_A(x)$
- Cardinalité, notée  $|A|$ , qui indique le degré total avec lequel les éléments de  $X$   $\sum_{x \in X} \mu_A(x)$

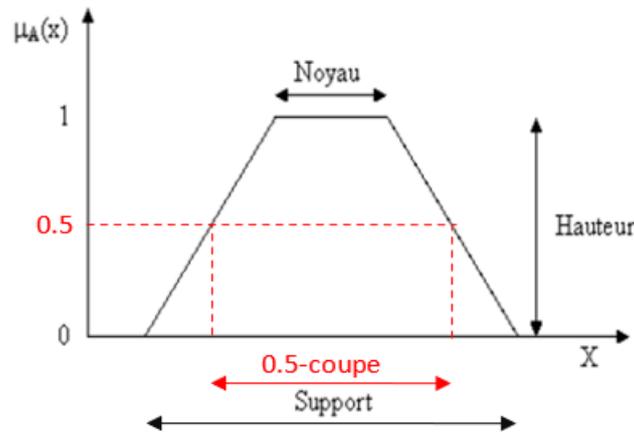


FIGURE 3.2 – Caractéristiques d'un sous-ensemble flou

### 3.6.2.3 Éléments de base de la théorie des possibilités

Nous distinguons les éléments de base de la théorie de possibilités : Nécessité de possibilité et distribution de possibilité. Plusieurs applications de la théorie des possibilités ont permis de mettre en valeur son apport.

#### □ Nécessité de possibilité

Une mesure de possibilité est une fonction  $\pi$  de  $X$  dans  $[0, 1]$  qui vérifie les équations du système :

$$\begin{aligned}\pi(\phi) &= 0 \\ \pi(S) &= 1\end{aligned}\tag{3.1}$$

$$\forall I \subset IN, \forall A_i \subseteq X(i, \in I), \pi(\bigcup_{i \in I} A_i) = \sup_{i \in I} \pi(A_i)$$

Par dualité, une mesure de nécessité est définie comme une fonction  $N$  de  $X$  dans  $[0, 1]$  telle que :

$$\forall A \subseteq S, N(A) = 1 - \pi(A^c), \text{ avec } A^c \text{ désigne le complément de } A.$$

Cette dualité signifie que si un événement est nécessaire, son contraire est impossible. Une mesure de nécessité vérifie les propriétés suivantes :

$$\begin{aligned}N(\phi) &= 0 \\ N(S) &= 1\end{aligned}\tag{3.2}$$

$$\forall I \subset IN, \forall A_i \subseteq X(i, \in I), N(\bigcap_{i \in I} A_i) = \inf_{i \in I} \pi(A_i)$$

Les mesures de possibilité et de nécessité ont de plus les propriétés suivantes :

- $\forall A \subseteq X, \max(\pi(A), \pi(A^c)) = 1$ , qui exprime le fait que l'un des deux ensembles  $A$  et  $A^c$  est complètement possible ;
- $\forall A \subseteq X, \min(N(A), N(A^c)) = 0$ , qui exprime que deux événements contraires ne peuvent pas être simultanément nécessaires ;
- $\forall A \subseteq X, \pi(A) > N(A)$  (un événement doit être possible avant d'être nécessaire) ;
- $\forall A \subseteq X, N(A) > 0 \implies \pi(A) = 1$ , car :
 
$$\begin{aligned}N(A) > 0 &\implies 1 - \pi(A^c) > 0 \implies \pi(A^c) < 1 \\ \max(\pi(A), \pi(A^c)) &= 1 \\ \implies \pi(A) &= 1\end{aligned}$$
- $\forall A \subseteq X, \pi(A) < 1 \implies N(A) = 0$ , car :
 
$$\begin{aligned}\pi(A) < 1 &\implies 1 - \pi(A) > 0 \text{ Or } N(A^c) = 1 - \pi(A) \\ N(A^c) > 0 &\text{ Or } \min(N(A), N(A^c)) = 0 \\ N(A) &= 0\end{aligned}$$

Ces deux propriétés expriment l'incertitude d'un événement  $A$  qui est caractérisée par deux valeurs : sa possibilité  $\pi(A)$  et sa nécessité  $N(A)$ .

- $\forall A \subseteq X, N(A) + N(A^c) \leq 1$  ;
- $\forall A \subseteq X, N(A) + N(A^c) \geq 1$

Ces deux dernières propriétés expriment la non-additivité des mesures de possibilité et de nécessité. La donnée de  $\pi(A)$  (respectivement  $N(A)$ ) n'est pas suffisante pour déterminer complètement  $\pi(A^c)$  (respectivement  $N(A^c)$ ), contrairement aux mesures de probabilité.

### □ Distribution de possibilité

Une distribution de possibilité est une fonction  $\pi$  de  $x$  dans  $[0, 1]$  avec la condition de normalisation suivante :

$$\sup_{x \in X} \pi(x) = 1 \quad (3.3)$$

Cette condition correspond à une hypothèse de monde fermé, dans lequel au moins un élément de  $X$  est complètement possible. Cette condition peut être relâchée dans une hypothèse de monde ouvert. Dans le cas fini, où  $C$  désigne l'ensemble des ensembles nets de l'univers  $X$ , une distribution de possibilité permet de construire une mesure de possibilité par la formule :

$$\forall A \in C, \pi(A) = \sup_{x \in A} \pi(x) \quad (3.4)$$

Inversement, une mesure de possibilité induit une distribution de possibilité :

$$\forall x \in X, \pi(x) = \pi(\{x\}) \quad (3.5)$$

Par dualité, une mesure de nécessité est définie à partir d'une distribution de possibilité par :

$$\forall A \in C, N(A) = 1 - \sup_{x \notin A} \pi(x) = \inf_{x \in A^c} 1 - \pi(x) \quad (3.6)$$

- $\pi(S) = 1$
- $N(A) > 0 \implies \pi(A) = 1$
- $\pi(A) < 1 \implies N(A) = 0$

### □ Applications de la théorie des possibilités

Plusieurs domaines ont bénéficié de l'apport de la théorie des possibilités, particulièrement, le domaine de traitement d'images. [Brown, 1992].

- Classification d'images satellites,
- Vision multi-caméras : classifications d'objets contenus dans une image capturée en utilisant plusieurs caméras ou capteurs,
- Segmentation des images,
- Reconnaissance d'images médicales 3D pour la détection d'anomalies,
- Classification d'images sonar : la théorie des possibilités est retenue pour la reconnaissance d'objets sous-marins acquis avec une caméra acoustique.

#### 3.6.2.4 Fondement mathématique de la théorie des possibilités

Les fondements mathématiques possibilistes sont rassemblés sous forme d'une extension des concepts flous. La notion d'appartenance graduelle à chaque ensemble reste la base fondamentale de cette théorie. Afin de tenir compte de l'incertitude à côté de l'ambiguïté ; la théorie des possibilités offre de nouvelles fonctions et interprétations [Touil et Kalti, 2016] [Alsahwa, 2014].

Étant donné un cadre de discernement,  $\Omega$  représente un ensemble exhaustif et exclusif de  $M$  classes singletons, la réalisation de l'unique classe  $C_i$  est estimée à travers deux mesures, appelés *possibilité*  $\Pi(\cdot)$  et *nécessité*  $N(\cdot)$ .

Le degré de confiance accordé à chaque élément de  $\Omega$  pour qu'il soit l'unique singleton qui va se construire est appelé *degré de possibilité* et noté par  $\pi$ . Ainsi, la distribution de possibilités associée à chaque élément de  $\Omega$  un degré dans l'intervalle  $[0, 1]$ . L'une des caractéristiques intéressantes de cette distribution est la possibilité d'attribuer à plusieurs observations un degré de possibilité maximal. Ceci s'interprète comme suit :

- **Ignorance totale :**

$$\forall C \in \Omega, \pi(C) = 1;$$

- **Ignorance partielle :**

$$\exists \text{ aux moins deux classes } C_i \text{ et } C_j \in \Omega \text{ tels que } \pi(C_i) = \pi(C_j) = 1;$$

- **Certitude :**  $\exists !C_i \in \Omega$  tels que  $\pi(C_i) = 1$  et  $\forall C_j \neq C_i, \pi(C_j) = 0, C_j \in \Omega$ .

Cependant, la gestion des cas de l'ignorance totale et de l'incertitude reste un défis continu. Dans ce contexte, les deux mesures duales  $\Pi$  et  $N$  se présentent et qui se sont dérivées de la distribution de possibilité  $\pi(\cdot)$ . Étant donné un événement composé  $A \subseteq \Omega$ , la possibilité et la nécessité de  $A$  s'obtiennent comme suit :

$$\begin{cases} \Pi(A) = \max_{C_i \in A} (\pi(C_i)); \\ N(A) = 1 - \Pi(\bar{A}). \end{cases} \quad (3.7)$$

avec  $\bar{A}$  désigne l'évènement complémentaire de  $A$ .

$\Pi$  permet d'estimer la possibilité que l'unique classe qui va se produire appartienne à cet événement. En outre, la mesure de nécessité permet d'estimer la certitude de la réalisation de l'évènement  $A$ . Si  $N(A) = 1$ , la réalisation de l'évènement  $A$  est complètement certaine (l'unique classe qui va se réaliser est forcément dans  $A$ ). Dans le cas contraire,  $N(A) = 0$  l'incertitude de la réalisation de  $A$  est maximale.

Les mesures vérifient les propriétés mathématiques sont comme suit :

- $\Pi(\emptyset) = 0$  et  $N(\emptyset) = 0$ ;
- $\Pi(\Omega) = 1$  et  $N(\Omega) = 1$ ;
- $\forall A, B \subseteq \Omega, \Pi(A \cup B) = \max(\Pi(A), \Pi(B))$ ;
- $\forall A, B \subseteq \Omega, N(A \cup B) \geq \max(N(A), N(B))$ ;
- $\forall A, B \subseteq \Omega, \Pi(A \cap B) \leq \min(\Pi(A), \Pi(B))$ ;
- $\forall A, B \subseteq \Omega, N(A \cap B) = \min(N(A), N(B))$ .

### 3.7 Approche de recalage basée sur une projection sémantique

Dans le cadre de notre travail nous exploitons la théorie de possibilité pour la transformation de la base de connaissance des images au niveau pixelique en une base de connaissance au niveau sémantique.

### *Pourquoi la théorie des possibilités ?*

Bien que la théorie des possibilités semble simple et se croise avec le raisonnement humain, cette théorie reste peu sophistiquée pour manipuler des informations hautement conflictuelles, de traiter conjointement des sources représentées par des cadres de discernements différents et traiter le cas de l'ignorance totale.

Afin de remédier aux limites du recalage ; nous proposons d'appliquer un processus de projection de connaissances dans le cadre du recalage d'images. Il s'agit de projeter les distributions des connaissances au niveau des images à recaler (source et cible) sur un ensemble d'images s'appuyant sur un seul contenu sémantique. Cet ensemble d'images est nommé *cartes de possibilités*.

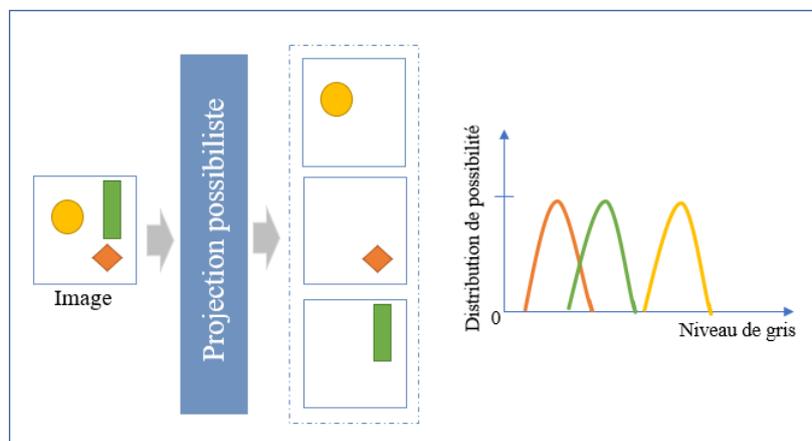


FIGURE 3.3 – Génération des cartes possibilistes

Comme illustré dans la figure 3.3 le processus de projection se base sur la théorie de possibilité pour la génération de l'ensemble des cartes. Ce processus est à appliquer sur les deux images à recaler ; *image source* et *image cible*.

L'objectif de cette projection est la création d'un nouvel espace de représentation de connaissances au niveau sémantique, qui est similaire au raisonnement humain pour minimiser au mieux le risque de conflit entre les contextes des images à recaler lors de la mise en correspondance. En effet, la nouvelle approche consiste à rechercher une fonction de transformation du recalage à partir des mises en correspondance entre l'ensembles des projections issues des cartes originales (i.e., carte à recaler) et non pas à partir de la mise en correspondance des images à recaler [Marzouka *et al.*, 2020a].

#### • Contextes de projection

La phase de projection nécessite un ensemble de connaissances sur les classes qui existent des images. C'est pour cela que notre approche nécessite la mise en place d'un processus de classification afin d'assurer une bonne génération de cartes de possibilités.

Dans ce cadre, deux contextes se présentent :

-1- **Contexte supervisé** : Classification supervisée,

-2- Contexte non supervisé : Classification non supervisée.

Pour le contexte supervisé, les classes sont définies par un modèle d'apprentissage intelligent qui fournit un ensemble fini de classes des deux images à recaler à partir d'un échantillon d'apprentissage. Pour le contexte non supervisé nous sommes contraints d'appliquer une méthode de classification non supervisée afin de définir les classes des deux images (images source et image cible).

Nous présentons dans la section suivante les méthodes de classification d'images existantes selon les deux contextes : supervisé et non supervisé. Nous justifions l'apport du choix des méthodes utilisées pour notre approche à l'aide d'une étude comparative de l'ensemble des méthodes de classification. Chacun de ces deux contextes permet d'obtenir un ensemble de classes qui seront les paramètres d'entrées de notre processus de projection. La fiabilité des résultats au niveau de la phase de classification est très importante pour assurer une meilleure projection.

### 3.8 Projection sémantique supervisée

La classification dans un contexte supervisé consiste à définir des règles permettant de classer des objets dans des classes à partir de variables qualitatives ou quantitatives caractérisant des objets.

#### 3.8.1 Présentation

Pour appliquer une classification supervisée [Baggio, 2012], nous disposons au départ d'un échantillon dit "échantillon d'apprentissage" fourni *a priori* et dont le classement est connu [Klette, 2014]. Ce dernier est utilisé pour l'apprentissage des règles de classement. Il est nécessaire d'étudier la fiabilité de ces règles pour les comparer et les appliquer, évaluer les cas de sous apprentissage ou de sur apprentissage (complexité du modèle) ; c'est pour cela que nous utilisons souvent un deuxième échantillon indépendant, dit de validation ou de test. La figure 3.4 illustre le schéma global de la classification supervisée.

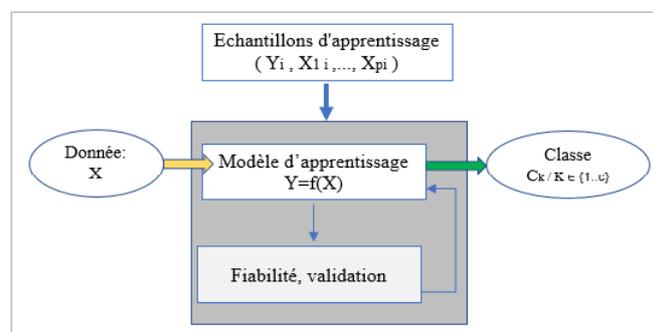


FIGURE 3.4 – Schéma global de la classification supervisée

Nous distinguons des différentes stratégies d'apprentissage :

- **Règle majoritaire** : Pour chaque donnée (Pixel de l'image), une classe  $k$  est associée telle que  $P(k)$  est maximale.

- **Règle du maximum de vraisemblance** : Pour chaque donnée (Pixel de l'image), une classe  $k$  est associée telle que  $P(d/k)$  maximale
- **Règle de Bayes** : Pour chaque donnée (Pixel de l'image), une classe  $k$  est associée telle que  $P(k/d)$  maximale.

### 3.8.2 Méthodes de classification supervisée existantes

La classification supervisée est basée sur l'apprentissage automatique qui vise à apprendre un modèle formel à partir de données observées.

Nous pouvons formaliser le problème de classification supervisée comme suit ; soit :

- $X$  un espace d'entrée,
- $Y$  un espace des cibles (fini en classification),
- $Z$  une variable aléatoire tel que  $Z = (X, Y)$  à valeur dans  $X \times Y$ ,
- $(x, y) \in X \times Y$  des exemples de couples tirés selon la distribution jointe

$$P(Z = (x, y)) = P(X = x)P(Y = y|X = x) \text{ si } P(X = x) \neq 0$$

- $D$  distribution sur  $Z = X \times Y$ ,
- $E = \{(x_i, y_i)\}_{i=1}^n$  échantillon de  $n$  valeurs aléatoires Indépendamment et Identiquement Distribuées (IID) suivant  $D$ .

A partir de  $E$ , nous cherchons à trouver :

$$f : X \rightarrow Y \text{ telle que } \tilde{h} = \operatorname{argmin}_h R(f) \text{ où } R(f) = P_{(X,Y) \sim D}(f(X) \neq Y) = P(f(X) \neq Y)$$

Nous présentons dans ce qui suit les approches de classification supervisée existantes afin de justifier notre choix de la méthode utilisée pour notre système de recalage proposé.

#### 3.8.2.1 Les approches discriminantes

Les approches discriminantes sont des approches fondées sur l'apprentissage d'un modèle discriminatif dont la probabilité conditionnelle de la cible  $Y$  est considérée comme une observation.

$X$  : modélisation de  $P(Y|X = x)$  ; seuil de décision.

Il existe deux catégories d'approche discriminantes, qui sont, les approches par séparation linéaire et les approches du type non linéaire.

Parmi les méthodes de cette approche nous distinguons deux catégories qui sont comme suit :

- **Méthodes de régression logistique** : Méthodes d'analyse basées sur la prédiction d'une valeur de données à partir des observations réelles d'un jeu de données (échantillon), ce type de méthode appartient à la famille des méthodes basées sur des modèles transparents qui donnent des résultats compréhensibles par l'utilisateur.
  - **Arbres de décisions** : C'est un classifieur qui est présenté sous la forme d'une structure arborescente et qui fournit des règles faciles à interpréter par humain,
  - **Les K- plus proches voisins** : C'est un classifieur qui n'admet pas de fonction précise d'apprentissage pour qu'il prédise la classe des nouvelles instances. Dans le cas des jeux

de données de petites dimensions, ce modèle a la capacité de fournir à l'utilisateur un certain type explication concernant la classification de chaque nouvelle instance.

- **Méthodes de perception** : Ce type d'apprentissage est basé principalement sur la perception. Elle appartient à la famille de modèle dit boîte noire puisqu'elle ne fournit pas de résultats faciles à interpréter par l'utilisateur.
  - **Machines à Vecteurs de Support (SVM)** : C'est une méthode de classification admettant un modèle qui cherche à trouver l'hyperplan optimal qui sépare au mieux les données dans l'espace d'entrée. Les seules informations fournies par ce modèle sont en général soit les vecteurs de support sans aucune autre information, soit les coefficients de l'hyperplan de séparation et éventuellement le taux de bonnes classifications. L'utilisateur trouve donc une difficulté d'expliquer ce qui fait qu'un pixel de l'image est affecté à une classe plutôt qu'à une autre. Ce type de méthode est très fiable en terme de précision.
  - **Réseaux de neurones artificiels(ANN)** : Cette approche s'appuie sur les neurones formels représentés par les perceptrons mono ou multi-couches. Le modèle de cette méthode est composé d'un ensemble de couches, il reçoit les informations sur une couche réceptrice de "neurones". Le traitement des données se fait dans un premier temps avec ou sans l'aide d'une ou plusieurs couches "cachées" contenant un ou plusieurs neurones. Par la suite, il aura une production d'un ou plusieurs signaux de sortie qui sont généralement des vecteurs de lien de connexion et qui ne donnent aucune indication supplémentaire sur la contribution des variables lors de la classification supervisée.

### 3.8.2.2 Les approches génératives

Ce type d'approche se repose sur deux variables :  $X$ , une variable observée et  $Y$  une variable cible. Le modèle génératif est le modèle statistique de la distribution jointe  $P(X, Y)$ .

- **Classification naïve de Bayes** : Il s'agit d'une classification bayésienne probabiliste simple (dite naïve). Elle repose sur le théorème de Bayes, qui n'est autre qu'un modèle de probabilités. Ce type de classification simple permet à un modèle d'apprentissage d'apprendre rapidement. Il n'est pas nécessaire de fournir un gros volume de données lors de la phase d'apprentissage. Son exécution est, en plus, très rapide, comparé à d'autres méthodes de classification supervisée plus complexes et lourdes à mettre en œuvre.

La classification naïve bayésienne offre des résultats très efficaces dans des domaines variés.
- **Analyse linéaire discriminante** : L'analyse discriminante linéaire est une méthode de référence en classification supervisée. Elle peut être appréhendée de deux façons complémentaires. Une approche géométrique qui revient à chercher des hyperplans qui séparent au mieux les groupes de données et une approche modèle qui fait l'hypothèse que les variables sont des covariables sont des vecteurs gaussiens avec des valeurs de paramètres différentes pour chaque groupe de données.

Nous distinguons ainsi d'autres approches permettant la classification et qui ont la particularité, d'être une méthode qui mélange un ensemble de modèles pour la classification tel que *les méthodes ensemblistes*.

### 3.8.3 Études comparatives des méthodes existantes

Le modèle construit par une stratégie d'apprentissage doit satisfaire un certain nombre de critères de performance principalement liées au "Taux d'erreur". En effet, la valeur du taux d'erreur doit être la plus faible possible et la moins sensible aux fluctuations aléatoires des données d'apprentissage. Pour calculer le taux d'erreur nous pouvons utiliser de nombreux critères d'évaluation tel que la précision, l'aire sous la courbe de ROC, l'indice ARI,...

Le Tableau 3.2 présente une comparaison de quelques modèles de la classification supervisée en se basant sur des critères de pertinence. Dans ce tableau nous utilisons deux symboles : (+) qui désigne la satisfaction du critère, et (-) désigne la non satisfaction du critère. Nous précisons ainsi que le nombre de symboles, dans chaque case, augmente le taux de satisfaction des critères.

TABLEAU 3.2 – Étude comparative des méthodes de classification supervisée

Critère	Arbre de décision	SVM	Plus proche voisin	Bayésien naïf
<b>Rapidité d'apprentissage</b>	+	--	++	+
<b>Rapidité et facilité de mise à jour</b>	--	-	++	++
<b>Précision</b>	++	++	+	+
<b>Simplicité</b> Nbre de paramètres	-	-	++	++
<b>Rapidité de classement</b>	++	-	-	++
<b>Interopérabilité</b>	++	-	++	++
<b>Sensibilité au bruit</b>	-	+	-	++

Des états de l'art plus détaillés sont disponibles, le lecteur souhaitant une description plus avancée de ces modèles pourra s'y référer [Khan *et al.*, 2021], [Liu *et al.*, 2021] et [Panigrahi *et al.*, 2021]. Loin de vouloir donner une description détaillée des différentes méthodes de la classification supervisée, cette section présente l'ensemble de méthodes de classification existantes afin de justifier le choix de la méthode utilisée.

### 3.8.4 Méthode proposée

La performance prédictive du modèle de classification est le point clé pour la garantie d'une meilleure projection dans notre travail. Les méthodes de classification utilisées dans ce cadre privilégient plus le critère de performance prédictive que celui de l'interprétation du résultat de la méthode de classification utilisée. Nous rappelons que les modèles de la classification supervisée se décomposent en deux grandes familles : *les modèles transparents* et *les modèles boîtes noires*.

Les modèles transparents englobent tous les algorithmes d'apprentissage qui fournissent des résultats facilement interprétables par l'utilisateur, à titre d'exemple, les arbres de décision, les k plus proches voisins). Tant dis ce que les modèles boîtes noires nommés aussi opaques désignent

les algorithmes d'apprentissage fournissant des résultats plus complexes pour la compréhension de l'utilisateur tel que *SVM* et *ANN*.

Dans notre travail, nous nous intéressons aux méthodes de classification supervisées admettant le critère de précision le plus élevé. Nous pouvons bien remarquer que les méthodes de classification de la famille boîte noire présentent une meilleure précision, c'est pour cela que nous proposons d'exploiter les méthodes de cette famille pour obtenir l'ensemble des classes en utilisant la distribution de possibilité sur l'ensemble des classes. Cette combinaison permet d'obtenir une meilleure performance en terme de précisions. Ces derniers seront les paramètres d'entrée de notre phase de projection sémantique.

### 3.9 Projection sémantique non supervisée

Les méthodes de la classification non supervisée ont pour objectif de retrouver une typologie existante caractérisant un ensemble d'observations nommé  $n$ , à partir d'un ensemble de caractéristiques nommé  $p$  et mesurées sur chacune des observations.

Nous nous focalisons sur cette problématique de définition d'un cadre de discernement exhaustif et exclusif en l'absence de vérité de terrain et des connaissances d'experts (système d'apprentissage). Pour cela, deux principaux besoins sont mis en question qui sont :

- La détermination du nombre de classes dans une image,
- La caractérisation de ces classes et leurs contenus informationnels.

L'apprentissage non supervisé de l'image et la caractérisation des classes est un traitement connu sous le nom de "clustering ". C'est une méthodologie qui vise à regrouper les caractéristiques, les objets et même les sémantiques d'une image en des ensembles distincts appelés souvent des classes.

Les éléments d'une classe donnée partagent les mêmes caractéristiques tout en étant différents par rapport à ceux des autres classes.

Pour résumer, le clustering désigne l'ensemble des méthodes de classification non supervisée des patrons indépendamment de leurs natures et leurs structures (pixels, objets, ontologies, vecteurs de caractéristiques...). Le clustering a été abordé dans plusieurs contextes d'applications et dans plusieurs disciplines de recherche afin de réaliser un apprentissage non supervisé, la segmentation, la reconnaissance d'objet, la fouille de données et la prise de décision [Moumjid *et al.*, 2009, Chuang *et al.*, 2016].

Le nombre d'algorithmes et de techniques de clustering ne cesse d'augmenter afin d'offrir une meilleure caractérisation des clusters tout en optimisant la complexité temporelle, et en tenant compte des types des données et des bruits qui peuvent les accompagner.

En effet, un algorithme de classification non supervisé doit assurer une homogénéité maximale de chaque classe et une dissimilarité maximale entre les paires de classes. Pour obtenir un résultat de clustering ayant ces deux principales caractéristiques, les algorithmes de clustering utilisent une mesure de similarité pour la comparaison des cluster et ses éléments.

### 3.9.1 Méthodes de clustering existantes

Nous présentons dans cette section les algorithmes de classification non supervisée les plus cités dans la littérature. Nous rappelons que pour la majorité des algorithmes, chaque classe est représentée par un élément spécifique appelé *centroïde* ou *vecteur prototype* et que les taxonomies des méthodes sont multiples et dépendent de l'intérêt visé.

C'est pour cela que nous nous intéressons aux méthodes de clustering hiérarchique et celles basées sur la représentation par les centroïdes.

#### 3.9.1.1 Classification hiérarchique

Les données de ces méthodes sont classifiées sous forme de différents niveaux de granularité ayant une allure d'un arbre binaire de clusters sous forme d'une représentation hiérarchique appelée *dendrogramme*. Nous distinguons deux familles d'approches hiérarchiques qui se différencient par la façon de raisonnement utilisée qui sont les approches ascendantes et les approches descendantes.

La première famille d'approche procède avec un processus de clustering utilisant un seul objet pour chaque cluster, le nombre de clusters est calculé en fonction du nombre d'objets. Par la suite, les clusters seront fusionnés au fur et à mesure afin d'obtenir un seul groupe d'objets à la fin du processus. Nous citons quelques méthodes ascendantes telles que *ALINK*, *CLINK*, *SLINK*, *CURE*, *CHAMELON* [Sneath *et al.*, 1973, Guha *et al.*, 1998, Karypis *et al.*, 1999].

La deuxième famille d'approche englobe les méthodes descendantes. En fait, elle commence par un ensemble de données représenté par un seul cluster et elle le divise récursivement en un ensemble d'autres clusters. Le processus de classification s'arrête lorsqu'un critère de convergence est vérifié.

Parmi les algorithmes hiérarchiques descendants (par division), nous citons *MONA* et *DIANA* (Divisive Analysis), *PDDP* (Principal Direction Divisive Partitioning) qui sont détaillés dans les travaux suivants [Kaufman et Rousseeuw, 2009, Boley, 1998].

La méthode *Clustering hiérarchique* souffre principalement de la complexité temporelle qui dépasse  $O(n^2)$  pour la majorité et qui peut atteindre  $O(n^3)$  [Klypin *et al.*, 2002]. Un autre inconvénient de cette famille d'algorithmes est l'aspect non itératif. Pour un cluster obtenu par fusion ou par division il n'est plus possible de le réviser à nouveau. Cependant, les algorithmes hiérarchiques sont très sensibles aux bruits et ne peuvent pas être appliqués avec des données volumineuses car ils sont très coûteux en terme de complexité temporelle et spatiale [Xu et Wunsch, 2005].

#### 3.9.1.2 Classification par regroupement

Les algorithmes de classification par regroupement sont basés sur les vecteurs prototypes tels que le *C-Moyennes-Flous*, *K-moyennes*, *K-harmonique moyenne* et *Espérance Maximisation* (EM) [Bezdek *et al.*, 1984, MacQueen, 1967, Zhang *et al.*, 1999, Dempster *et al.*, 1977].

En fait, ces algorithmes se basent sur la représentation de chaque classe par un centroïde. Ces derniers sont initialisés manuellement ou aléatoirement. Par la suite, ils sont mis à jour jusqu'à

la convergence itérative de l'algorithme. La prise de décision se base sur la convergence à l'aide de certains critères.

La méthode de classification par regroupement se distingue par sa rapidité de convergence (complexité linéaire) et sa simplicité d'implémentation par rapport à la famille d'approches hiérarchique.

### 3.9.1.3 Méthode de classification C-Moyennes-Floues (FCM)

L'algorithme C-Moyennes-Floues « Fuzzy-C-Means » (*FCM*) est l'un des algorithmes de clustering les plus répandus dans différents domaines de recherche tels que la classification des images médicales et satellitaires, la fouille de données [Masood et Ali Al-Jumaily, 2013]. Il présente une combinaison de l'algorithme *K-means* [MacQueen, 1967] et la théorie des ensembles flous définie par [Zadeh, 1968]. Cette méthode a été développée par [Dunn, 1973] et améliorée par [Bezdek et al., 1981]. L'intégration de la notion floue dans la définition des centroïdes donne l'avantage aux pixels d'avoir un degré d'appartenance non nul à chaque classe. Ainsi, la notion de chevauchements entre les clusters est prise en compte contrairement à l'algorithme de clustering dur *K-means*. En conséquence, l'ambiguïté d'appartenance est traitée ce qui présente l'avantage principal de cet algorithme.

Soit  $X = x_1, \dots, x_N \in R^b$  l'ensemble des données b-dimensionnelles où les  $x_i$  peuvent être des pixels, des objets, des vecteurs caractéristiques et même des patrons. On cherche à partitionner  $X$  en  $M$  clusters où  $M$  et  $X$  sont fournis comme paramètres d'entrée. L'algorithme FCM se base sur l'optimisation itérative d'une fonction objective qu'on note par  $J$  afin de trouver la combinaison optimale des centroïdes  $V = v_1, \dots, v_M$  associés aux clusters. Cette combinaison se caractérise par l'homogénéité, la compacité et la séparation maximales des clusters. En effet, l'algorithme converge si et seulement si  $J$  évolue de peu entre deux itérations successives.

$$J^{(t)} = \sum_{i=1}^M \sum_{j=1}^N \mu_{ij}^m * \|x_i - v_j\|^2 \quad (3.8)$$

avec  $\|x_i - v_j\|$  est la distance entre l'élément  $x_i$  et le centroïde  $v_j$  qui est souvent la distance euclidienne. Initialement, les  $M$  centroïdes sont choisis aléatoirement. Le degré d'appartenance noté  $\mu_{ij}$  de chaque  $x_i$  à chaque  $v_j$  à l'itération  $t$  est obtenu par l'équation suivante :

$$v_j^{(t)} = \frac{\sum_{i=1}^N \mu_{ij}^{m * x_i}}{\sum_{i=1}^N \mu_{ij}^m} \quad (3.9)$$

Les équations 3.8 et 3.9 sont mises à jour à chaque itération jusqu'à la vérification de la condition :

$$|j^t - j^{t-1}| < \epsilon \quad (3.10)$$

Les degrés d'appartenance d'un élément  $i$  de l'ensemble  $X$  à chaque cluster  $j$  constituent sa distribution d'appartenance. L'ensemble des distributions d'appartenance associées aux  $N$  éléments de  $X$  forment la matrice de partition notée  $U$  :

$$U = \begin{bmatrix} \mu_{11} & \dots & \mu_{1M} \\ \dots & \dots & \dots \\ \dots & \dots & \dots \\ \mu_{N1} & \dots & \mu_{NM} \end{bmatrix} \quad (3.11)$$

L'algorithme FCM est fréquemment appliqué grâce à sa capacité de tenir compte de l'aspect flou des classes et des objets.

Bien que l'algorithme *FCM* présente certains avantages, il reste limité à cause de sa sensibilité aux bruits, à la variation intra-classes et à l'initialisation aléatoire des centroïdes. En effet, le degré du bruit que ce soit faible ou élevé sera attribué aux classes. D'autre part, le choix aléatoire des centroïdes peut participer à l'élévation de la complexité temporelle. Cependant, cette dernière reste la moins élevée par rapport à celles engendrées par d'autres algorithmes notamment ceux de la famille d'approches hiérarchiques.

#### 3.9.1.4 Clustering multi-centroïdes basé sur le FCM

Cet algorithme vise à assurer une meilleure caractérisation des classes présentes dans une image par rapport à l'algorithme *FCM* standard. Il présente l'avantage d'exploiter les images caractéristiques d'une nouvelle façon moins couteuse en termes de complexité temporelle où les centroïdes obtenus à l'issue de l'application de l'algorithme *FCM* ne sont pas forcément tous considérés.

En effet, cette méthode prend en compte le fait que les centroïdes identifiés ne sont pas forcément représentatifs soit à cause d'une redondance ou à cause d'une dissimilarité.

L'application de l'algorithme FCM sur chaque image caractéristique est beaucoup moins couteuse que de l'exécuter sur un grand ensemble d'images. Finalement, la fusion des fonctions d'appartenances permet de réduire l'ambiguïté sur l'appartenance des pixels.

### 3.9.2 Méthode proposée

L'étude de l'existant réalisée nous a amené à proposer une méthode qui combine la distribution de possibilité et la méthode de clustering multi-centroïde basée sur l'algorithme FCM afin de renforcer la performance de la phase de projection grâce à la précision élevée des deux tiers. Le choix est principalement basé sur la performance au niveau de précision élevée par rapport aux autres méthodes de clustering.

## 3.10 Génération des cartes de possibilité

L'apport principale de l'approche de recalage possibiliste que nous proposons repose sur la phase de projection de connaissances permettant la génération d'un ensemble de sous images nommées "cartes de possibilité" liée chacune un seul contenu sémantique. Nous présentons dans la section suivante les méthodes utilisées pour la génération des cartes sachant que notre processus

de projection prend en entrée les deux images à recalcr et leurs classes sémantiques selon le contexte utilisé (supervisé ou non supervisé).

### 3.10.1 Contexte supervisé

Le cas supervisé suppose le recours à un expert pour la définition du cadre de discernement. Le nombre de classes ainsi que des portions types caractéristiques de chacune des classes seront exploités pour l'apprentissage du système.

#### 3.10.1.1 Apprentissage

Il s'agit de fixer le nombre de classes contenues dans l'image à recalcr et de définir à travers des polygones des échantillons de classes qui vont être utilisés pour la représentation des classes. Chaque classe va donc être définie par l'intermédiaire des zones d'observations prédéfinies au niveau de cette phase d'apprentissage.

#### 3.10.1.2 Modélisation de l'approche

Nous supposons que les données disponibles consistent en  $N$  zones d'observations réparties en  $k$  classes de  $\Omega$  suivant une distribution de probabilité  $IP_x$ .

Soit  $n_i$  le nombre d'observations se répartissant dans la  $i^{\text{ème}}$  classe  $C_i$ .

Le vecteur  $n = (n_1, \dots, n_k)$  est la réalisation d'une variable aléatoire multinomiale de paramètres  $p = (p_1, \dots, p_k)$  où chaque  $p_i = IP_x(C_i) > 0$  est la probabilité d'apparition de la  $i^{\text{ème}}$  classe (ou proportion de la classe  $i$ ), avec :

$$\sum_{i=1}^k (P_i = 1) \tag{3.12}$$

Cette approche consiste à estimer les  $p_i$  à l'aide d'intervalles de confiance simultanés avec un niveau de confiance donné  $1 - \alpha$  sur les proportions d'une loi multinomiale, puis à en déduire une distribution de possibilités qui dominera la vraie distribution de probabilité dans au moins  $100(1 - \alpha)\%$  des cas. Calculer l'intervalle de confiance  $[p_i^-, p_i^+]$  revient à résoudre l'équation Eq (3.13). Cette équation a deux solutions qui définissent les limites inférieures et supérieures de l'intervalle de confiance (??).

$$p_i^2(N + x^2(1 - \alpha, 1)) - (2n_i + x^2(1 - \alpha, 1))p_i + \frac{n_i^2}{N} = 0, \forall i = 1, k \tag{3.13}$$

avec :

$x^2(1 - \alpha/K, 1)$  le quantile de niveau  $1 - \alpha/k$  d'une distribution du  $x^2$  à un degré de liberté.

#### 3.10.1.3 Calcul des distributions de possibilités

Il s'agit de chercher la distribution de possibilités, sur  $\Omega$ , la plus spécifique dominante toute distribution de probabilité définie par  $p_i \in [p_i^-, p_i^+], \forall i$  [16]. La solution du problème peut être obtenue de la manière suivant l'Eq (3.14) :

Soit  $P$  l'ordre partiel induit par les intervalles  $[p_i] \in [p_i^-, p_i^+]$  tels que  $(C_i, C_j) \in P \Leftrightarrow p_i^+ < p_j^-$  et

$\wedge(P) = \{L_l, l = 1..L\}$  l'ensemble de ses extensions linéaires. Pour toute permutation possible  $\sigma_l$  associée à  $\wedge(P)$ , et chaque classe  $C_i$ , il s'agit de résoudre le programme linéaire suivant 3.15 :

$$\pi_i^{\sigma_l} = \max_{p_i, \dots, p_k \{j: \sigma_l^{-l}(j) \leq \sigma_l^{-l}(i)\}} \sum p_j \quad (3.14)$$

Sous la contrainte :

$$\left\{ \begin{array}{l} \sum_{i=1}^k p_i = 1 \\ p_i^- \leq p_i \leq p_i^+ \forall i \in \{1, \dots, k\} \\ p_{\sigma_l^1} \leq p_{\sigma_l^2} \leq \dots \leq p_{\sigma_l^k} \end{array} \right. \quad (3.15)$$

et retenir la distribution la plus spécifique dominante toutes les distributions  $\pi^{\sigma_l}$  3.15 :

$$\pi_i = \max_{\pi_i^{\sigma_l}} \forall i \in 1, \dots, k \quad (3.16)$$

Cette étape produit une distribution de possibilités pour chaque élément de  $F$  en se basant sur les données expérimentales (les histogrammes  $h_{ef_i}$  avec  $i \in \{1, \dots, k\}$ ).

### 3.10.2 Contexte non supervisé

Une étude approfondie des algorithmes de classification non supervisée a été engagée pour choisir la technique qui s'adapte à notre problématique de recalage. Nous avons opté d'avoir recours à l'algorithme Fuzzy-C-Means (*FCM*) pour l'apprentissage et la caractérisation des classes. Cet algorithme est largement répandu grâce à ses avantages en particulier sa capacité à gérer l'ambiguïté. L'algorithme FCM représente chaque classe par un centroïde unique, ce qui entrave son efficacité dans la caractérisation des classes.

Pour pallier à cette limite, nous utilisons un nouvel algorithme de clustering flou basé sur l'algorithme FCM et qui représente chaque classe par un nombre varié de centroïdes. Cet algorithme repose sur l'idée d'extraire des centroïdes séparément à partir des images caractéristiques dérivées de l'image en niveau de gris. En effet, représenter, les classes par un ensemble de centroïdes permet de réduire l'ambiguïté de la décision sur la vraie classe d'un pixel donné et, par conséquent, garantir d'une part une meilleure caractérisation des classes et d'autre part, l'exclusivité des classes. L'une des contraintes pour le cadre non supervisé concerne la détermination du nombre de classes. Il faut souligner que l'algorithme de clustering FCM et celui que nous avons proposé prennent le nombre de classes comme un paramétré d'entrée. Le problème de l'identification du nombre de classes est à l'origine d'un grand nombre de publications scientifiques qui ont essayé d'y trouver une solution. Dans ce cadre, les indices de validations de clustering (*CVI*) sont des mesures mathématiques permettant d'évaluer les résultats de clustering et en conséquence déduire le nombre de classes qui optimise le résultat. Malgré le développement d'une grande variété de *CVI*, il n'existe pas un indice capable de trouver le vrai nombre de classes dans chaque type de données. L'étude menée par [Haouas *et al.*, 2019] en matière d'évaluation des *CVI* existants sur différents types d'images a permis de constater l'instabilité de ces mesures mathématiques et leur incapacité à indiquer le vrai nombre optimal de classes. Ces observations ont été à l'origine de la proposition d'un nouvel *CVI* flou. Cet indice, qui se caractérise par son

comportement stable, nous a permis de garantir l'exhaustivité du cadre de discernement.

### 3.10.2.1 Indice de validité de clustering flou

Nous nous intéressons particulièrement aux indices de validité clustering internes (*CVI*). Ils sont désignés en internes internes car ils ne se basent sur des informations *a priori* externes. Ils permettent d'identifier les résultats de clustering avec le nombre de classes optimal. Les *CVIs* internes sont l'objet de très grand nombre de publications [Settouti, 2011]. Nous distinguons principalement deux familles de *CVIs* internes qui sont : les *CVIs* durs et les *CVIs* flous. Comme leur nom l'indique, la première famille ne prend pas en considération l'aspect flou des clusters (le chevauchement des partitions). Cependant, ils peuvent être appliqués pour évaluer les résultats issus des algorithmes flous. La deuxième famille a la capacité d'évaluer les résultats ayant des clusters ambigus et qui se chevauchent. Plusieurs indices existent dans la littérature, nous présentons ici les indices  $T$  et  $WL$  que nous avons retenu comme base pour introduire un nouveau indice. Le choix de ces deux *CVIs* est justifié par leurs comportements dans des expérimentations sur des images et aussi par les termes intéressants qui les présentent.

- **Indice de Tang ( $T$ )** : L'indice de Tang, noté  $T$ , a été proposé en 2005 [Zhang *et al.*, 2005]. Il utilise deux termes punitifs dans les expressions de séparabilité de compacité.

$$T = \frac{\sum_{j=1}^M \sum_{i=1}^N \mu_{ij}^2 \|x_i - v_j\|^2 + ADP}{\min_{i \neq j} \|v_i - v_j\|^2 + \frac{1}{M}} \quad (3.17)$$

$$ADP = \frac{1}{M * (M - 1)} \sum_{i=1}^M \sum_{k=1, k \neq i}^M \|v_i - v_k\| \quad (3.18)$$

avec ADP est un nouveau terme punitif qui généralise celui de Kown. Il est la moyenne des distances entre les paires des centroïdes. Le deuxième ad-hoc terme punitif est  $\frac{1}{M}$ . Il permet de remédier au problème de tendance vers l'infini lorsque le paramètre de fuzzification  $m$  s'en approche. Le nombre optimal de clusters est celui du résultat ayant le plus petit indice  $T$ .

- **Indice de Wu-Li (WL)** : Cet indice noté  $WL$  a été récemment proposé par Wu et Li dans [35]. Contrairement à la majorité des indices existants qui évaluent la séparation par la distance minimale entre les paires des centroïdes, l'indice  $WL$  introduit une nouvelle mesure qui combine les distances minimale et médiane comme montré par l'équation Eq (3.19) :

$$WL = \frac{\sum_{j=1}^M \frac{\sum_{i=1}^N \mu_{ij}^m \|x_i - v_j\|^2}{\sum_{i=1}^N \mu_{ij}}}{\frac{1}{2} * (\min \|v_i - v_j\|^2 + \text{median} \|v_i - v_j\|^2), i \neq j} \quad (3.19)$$

- Nouveau *CVI* : Indice HF

Dans notre travail, nous exploités un indice de validité un indice de validité de clustering appelé "*HF*" dédié à l'évaluation des résultats de clustering flou. Cet indice peut être vu en tant que l'amélioration et la combinaison des deux autres *CVIs* qui sont  $WL$  et  $T$ . En effet,

l'expérimentation de  $WL$  et  $T$  sur différents types d'images nous ont permis de constater que ces deux indices échouaient, dans la majorité des cas, à indiquer le vrai nombre optimal de classes. Les valeurs de  $T$  croient avec le nombre de classes malgré l'ADP impliqué. Par ailleurs, nous avons remarqué que l'indice  $WL$  a un comportement plus stable que  $T$  et parvenait à fournir une évaluation plus précise par rapport à l'indice de  $T$ . Cette combinaison a pour principal but de trouver le résultat de clustering qui engendre la meilleur séparabilité des classes où chaque classe est le plus compacte possible tout en palliant la limite majeure des indices qui est la monotonie décroissante. En outre, les termes intéressants dans les deux indices sont la médiane des distances qui séparent les centroïdes des classes dans l'indice  $WL$  et l'ad-hoc terme punitif dans l'indice  $T$ . Pour calculer la compacité des classes avec l'indice  $HF$  nous avons utilisé la mesure, typique, qui est la distance pondérée par les degrés d'appartenance entre chaque pixel et chaque centroïde :

$$\mu_{ij}^m \|x_i - v_j\|^2 \quad (3.20)$$

Cette distance est indépendante de  $m$  contrairement à l'indice  $T$  qui la force à la valeur 2. La mesure de compacité proposée est notée  $N_{HF}$  3.22.

$$N_{HF} = \sum_{j=1}^M \sum_{i=1}^N \mu_{ij}^m \|x_i - v_j\|^2 + ADP \quad (3.21)$$

Elle est le résultat de l'association de ADP ( $2^{ème}$  terme de l'équation 3.18) de Tang (ad-hoc terme punitif) et la distance pondérée. L'avantage principal de ce terme est la prévention de la monotonie décroissante lorsque le nombre de classes  $M$  s'approche de la cardinalité de l'ensemble des données  $X$ .

Le terme de séparation proposé est noté  $D_{HF}$  est donné par l'équation 3.22

$$D_{HF} = \frac{N}{2 * M} * (\min \|v_i - v_j\|^2 + \text{median} \|v_i - v_j\|^2), i \neq j \quad (3.22)$$

Finalement, l'indice proposé est le rapport de  $N_{HF}$  par  $D_{HF}$ . Le résultat optimal de clustering entraîne la valeur minimale de  $HF$ .

$$HF = N_{HF} \frac{N_{HF}}{D_{HF}} \quad (3.23)$$

L'objectif principal de l'algorithme exploité est d'assurer une meilleure caractérisation des classes présentes dans l'image par rapport à l'algorithme FCM standard. En effet, la représentation de chaque classe par un seul centroïde est insuffisante dans certaines situations, notamment, lorsque les classes ne sont pas homogènes et compactes. Ceci peut revenir au fait que les classes n'ont pas la même densité ou la même forme, et leurs frontières ne sont pas facile à identifier et à discriminer.

L'idée de l'algorithme proposé gravite autour de la représentation multi-centroïdes de chaque classe où les centroïdes sont déterminés à l'aide de l'algorithme FCM standard appliqué sur différentes images caractéristiques dérivées de l'Image Multispectrale  $Im$  (qui est considérée comme étant l'image référence). L'apprentissage des images caractéristiques permet de dégager d'autres

caractéristiques de classes. À partir de IM nous allons déterminer le nombre optimal de classes. Les classes identifiées sont représentées par un nombre varié de centroïdes. Ainsi, une étape de sélection de centroïdes pour chaque classe est appliquée. La dernière étape correspond à la génération de la distribution de degrés d'appartenance floue associés à chaque classe et le cadre de discernement formé par Cop classes sémantiques  $\Omega = C_1, \dots, C_{op}$ . La figure 3.5 illustre les étapes de caractérisation des classes du cadre de discernement.

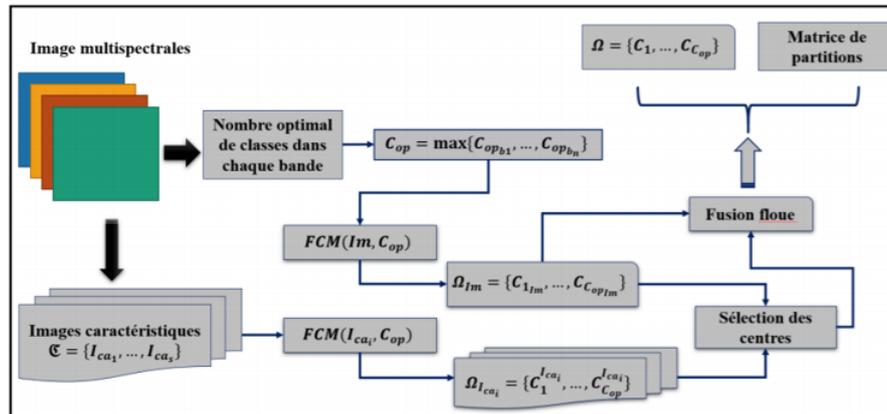


FIGURE 3.5 – Étapes de l’algorithme de clustering multi-centroïdes [Haouas *et al.*, 2019]

### 3.10.2.2 Phase de l’estimation

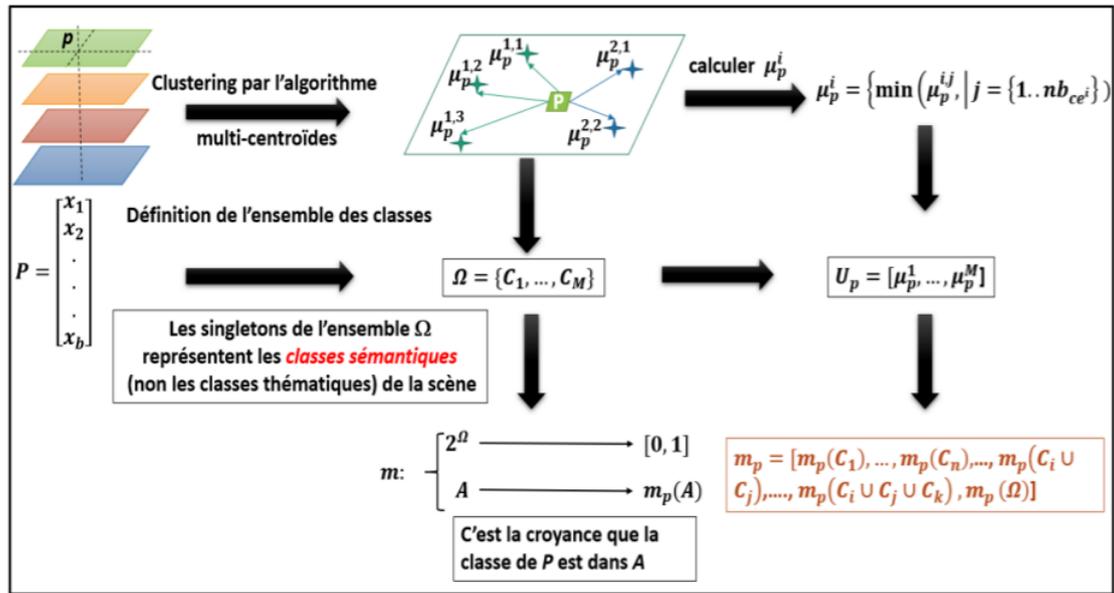
Après avoir modélisé le problème et identifié les classes, l’estimation de la fonction de masse et le choix des éléments focaux s’imposent. C’est une étape clé dans un processus de fusion ou de traitement par ce formalisme puisque la fiabilité de la décision est un facteur direct de la fiabilité de l’estimation. Cette étape consiste à représenter les informations acquises sous forme de distributions où chaque observation a un degré de confiance qui traduit la croyance en chaque élément focal.

### 3.10.2.3 Méthode pour l’estimation de la fonction de masse

L’ensemble des centroïdes  $V$  ainsi que les distributions d’appartenances associées offrent des connaissances riches sur les classes sémantiques de chaque pixel. La classe sémantique de chaque pixel est *a priori* connue. L’estimation des fonctions de masses comporte en réalité deux étapes qui sont la génération des centroïdes des classes (que nous avons explicité dans la section précédente) et le passage flou-masse qui consiste à définir une distribution de masses à partir de la distribution d’appartenance floue.

La figure 3.6 récapitule les grandes étapes suivies pour estimer la distribution de masse :

- Génération du cadre de discernement par l’algorithme de clustering proposé,
- Récupération des centroïdes relatifs à chaque classe,
- Détermination de la distributions d’appartenance,
- Calcul de la distribution de masse.

FIGURE 3.6 – Schéma global du passage pixel-centroïde-appartenance [Haouas *et al.*, 2019]

### 3.10.2.4 Estimation de la distribution de masse

L'ensemble des éléments focaux considérés est formée par 3 types qui sont : les singletons, un élément focal composé de deux singletons et l'ensemble  $\Omega$ . L'estimation de chaque type est obtenue à l'aide d'une expression spécifique.

#### • Masse attribuée à la classe singleton :

C'est la masse attribuée à une classe sémantique. Nous proposons d'exploiter l'information obtenue à l'issue de l'application de l'algorithme de clustering multi-centroïdes.

$$m'_p(C_k) = \mu_p(C_k), k \in 1, 2, \dots, M \quad (3.24)$$

#### • Masse attribuée à l'élément composé $C_i, C_j$ :

La masse de croyance associée à ce type d'élément doit vérifier trois conditions :

- Plus les centroïdes des classes  $C_i, C_j$  sont proches de  $P$ , plus la masse attribuée à ce couple est élevée ;
- Plus la différence  $|\mu_p(C_i) - \mu_p(C_j)|$  est petite, plus élevée la masse est supposée être ;
- La masse ( $m'_p(C_i, C_j)$ ) est supposée être proportionnelle à  $\min(\mu_p(C_i), \mu_p(C_j))$ . A partir de ces trois conditions intuitives, nous proposons de calculer la masse de  $C_i, C_j$  à l'aide de l'expression suivante :

$$m'_p(C_i \cup C_j) = \frac{\min(\mu_p(i), \mu_p(j))}{|\mu_p(i), \mu_p(j)| * \exp\left(-\frac{1}{1 + d_p(C_i, C_j)}\right)} \quad (3.25)$$

avec

$$d_p(C_i, C_j) = \sqrt{(P - V_i)^2 + (P - V_j)^2} \quad (3.26)$$

Le terme  $\frac{1}{\exp(-\frac{1}{1+d_p(C_i, C_j)})}$  est la mesure d'incertitude proposée. Elle est maximale lorsque  $d_p$  est proche de 0 (forte ambiguïté entre les classes).

— Masse attribuée à  $\Omega$  : La valeur de masse attribuée à l'ignorance est différente de 0 si le pixel P a la même distance minimale d'un couple de classes. Elle est calculée comme suit :

$$m'_p(\Omega) = \frac{\exp(-\frac{1}{1+d_{min}})}{n_{dmin}} \quad (3.27)$$

• Normalisation de la distribution de masses Les masses attribuées aux éléments focaux sont normalisées à l'aide de l'expression suivante :

$$m_p(A) = \frac{m'_p(A)}{\sum_{B \in F^{m'_p}} m'_p(B)} \quad (3.28)$$

### 3.11 Conclusion

Dans ce chapitre, nous avons modélisé la problématique de la génération des cartes de possibilités à partir des images source et cible et leurs classes sémantiques. Cette génération est issue d'une phase de projection des connaissances en utilisant la théorie des possibilités à travers définition d'un ensemble de distribution des différentes classes des deux images à recalcr.

Dans ce cadre, nous avons pris en considération deux contextes qui sont le contexte supervisé, où nous proposons d'utiliser une méthode de classification supervisé utilisant un modèle dis boite noir qui donne une performance élevée en terme de précision. Pour le contexte non supervisé, nous utilisons une méthode de clustering multicroïde basée sur la méthode *FCM*.

Nos choix de méthodes sont basée sur un critère d'évaluation très important pour la phase de projection qui est la précision.

Nous présentons dans le chapitre suivant, l'application de notre approche proposée dans les différents contextes.

# SYSTEME DE RECALAGE POSSIBILISTE

## Sommaire

<b>4.1</b>	<b>Introduction</b>	<b>69</b>
<b>4.2</b>	<b>Sources de connaissance pour le système de recalage</b>	<b>70</b>
4.2.1	Connaissance du niveau pixelique	71
4.2.2	Connaissances du niveau sémantique	74
<b>4.3</b>	<b>Description des classes sémantiques</b>	<b>76</b>
<b>4.4</b>	<b>Fusion de connaissances</b>	<b>77</b>
4.4.1	Principe	78
4.4.2	Estimation des distributions de possibilités	79
4.4.3	Fonctions de masse pour la fusion des connaissances	81
<b>4.5</b>	<b>Processus du recalage géométrique possibiliste proposé</b>	<b>82</b>
4.5.1	Extraction des primitives	83
4.5.2	État de l'art sur les méthodes d'extraction des primitives	84
4.5.3	Choix de la méthode d'extraction des primitives	86
4.5.4	Mise en correspondance des primitives	87
<b>4.6</b>	<b>Estimation du modèle de transformation</b>	<b>88</b>
<b>4.7</b>	<b>Le ré-échantillonnage et interpolation de l'image cible</b>	<b>89</b>
<b>4.8</b>	<b>Conclusion</b>	<b>89</b>

## 4.1 Introduction

Étant donné que les informations issues des images acquises à partir d'une même scène sont de nature complémentaire, la bonne mise en correspondance des données utiles obtenues à partir de ces images est d'un grand intérêt. Comme mentionné dans le deuxième chapitre, les méthodes du recalage de l'approche géométrique, repose sur le raisonnement humain et utilise un ensemble de caractéristiques géométriques ou visuelles pour le recalage. Les méthodes de cette famille d'approche offrent plusieurs avantages tels que le faible coût de calcul et la robustesse au bruit. Néanmoins, elles dépendent fortement de la qualité ainsi que de la précision des primitives extraites.

Nous rappelons que le processus de recalage géométrique d'une image source ( $Im_s$ ) et d'une image transformée ( $Im_t$ ) se réalise en trois phases principales ; sélectionner l'ensemble des primitives appelées points d'intérêt en fonction d'un détecteur de primitive, décrire les primitives

extraites des deux images source et cible par un ensemble de descripteurs et déterminer la fonction de transformation optimale entre les deux images ( $Im_s$ ) et ( $Im_t$ ) à l'aide de la mise en correspondance des deux images.

Ce processus de recalage est basé sur des connaissances au niveau de capteur appelé aussi *niveau numérique* ou encore *niveau de gris*. Ce niveau de connaissance est imprécis et peut causer une ambiguïté lors de la mise en correspondance des primitives des images à recaler. Ce conflit conduit à certaines limites au niveau de l'extraction des primitives telles que la répétabilité et la robustesse de la transformation d'image, conduisant ainsi à une faiblesse des résultats de mise en correspondance avec des effets négatifs sur les performances du recalage. Une autre limite au niveau de la recherche de la méthode de transformation optimale où la complexité temporelle est importante à cause de l'ambiguïté figurante dans l'ensemble des primitives à recaler.

Toutes ces contraintes ont des conséquences directes sur les performances de recalage. Par conséquent, la recherche de nouvelles approches de recalage d'images géométrique permettant de mettre limite aux problèmes dus au niveau de connaissance des images restent des défis importants et ouverts.

Afin de surmonter les limites des méthodes de recalage géométrique existantes nous proposons d'étaler la base de connaissances des images à recaler et d'exploiter les informations du niveau sémantique en plus des informations du niveau numérique pour travailler dans un espace de représentation de connaissances sémantique appelé aussi *niveau possibiliste*.

Ce chapitre comporte trois parties. Nous commençons par la présentation des niveaux de connaissance constituant notre base proposée. Nous passons par la suite à la définition de notre approche de recalage géométrique basée sur des connaissances semi-sémantiques. Ensuite, nous détaillons l'apport de notre approche qui se présente en la génération d'un ensemble d'images possibilistes à travers une phase de projection. Nous clôturons ce chapitre par une évaluation de la complexité de l'approche proposée.

## 4.2 Sources de connaissance pour le système de recalage

Nous distinguons plusieurs systèmes d'interprétation d'images dans des différents domaines d'application [Li, 2021]. Ces systèmes ont été conçus selon les motivations des auteurs. Ils diffèrent par un certain nombre d'aspects tels que l'objectif à atteindre, le niveau des connaissances disponibles et la méthode de leurs représentations, la méthodologie à suivre et finalement le domaine d'application.

Nous soulignons que la méthodologie utilisée par ces systèmes sert à classifier ces systèmes d'interprétation des images en différentes familles [Li, 2021] [Chen *et al.*, 2021]; il existe des systèmes basés sur des connaissances [Malandain, 2006], des systèmes basés sur une théorie de décision particulière [Kjer *et Wilm*, 2010] et des systèmes basés sur le mode de raisonnement [Borgefors, 1988].

En effet, la sémantique dans une image dépend de deux éléments ; du niveau des connaissances et de la perception et des objectifs de l'expert [Ardeshir, 2005]. En fait, cet objectif détermine la nature du processus d'interprétation et l'échelle de la zone d'étude ce qui définit ainsi la résolution spatiale et spectrale convenable.

Partant de ce constat, nous proposons de classifier les systèmes d'interprétation de scène en fonction des niveaux sémantiques sur lesquels l'interprétation est opérée. Ces niveaux sont :

- Le niveau sous-pixelique,
- Le niveau pixelique,
- Le niveau région,
- Le niveau objet,
- Le niveau scène.

Chaque niveau sémantique est caractérisé par les connaissances nécessaires et le mode de représentation pour mettre en œuvre les objectifs à atteindre. Plus le niveau sémantique devient abstrait, plus des connaissances *a priori* sont indispensables et plus les modes de représentation deviennent complexes et la gestion des imperfections devient cruciale.

Dans ce paragraphe, nous allons décrire chaque niveau sémantique d'interprétation, la représentation des connaissances associées et montrer des exemples de systèmes d'interprétation opérant sur ce niveau.

Un intérêt particulier est porté aux niveaux (pixelique et régions) explicitant les problèmes rencontrés tels que l'intervention de l'expert lors du processus d'interprétation (i.e. les paramètres à estimer), la représentativité des connaissances disponibles, l'exploitation du contexte spatial comme une source additionnelle de connaissances, la possibilité de mise en cause par l'expert des résultats obtenus aux niveaux supérieurs (région, objet et scène) et le traitement des imperfections.

#### 4.2.1 Connaissance du niveau pixelique

A ce niveau, les systèmes d'interprétation de scène considèrent le pixel comme la granularité informationnelle de base dans le processus d'interprétation, puisque ce pixel résulte d'une empreinte correspondant à une cellule de résolution du capteur. L'objectif consiste alors à identifier le contenu informationnel de chaque pixel individuellement. Ce contenu est associé soit à la classe unique du pixel (parmi les différentes classes de la scène), soit à un élément d'information caractérisant chaque pixel : information de détection de changement, des paramètres physiques (taux d'humidité, rugosité, etc.), des paramètres 3D permettant la construction d'un modèle numérique de terrain,...

Au niveau pixelique, les connaissances à priori sont basées soit sur les informations du niveau sous pixelique (i.e., l'appartenance de chaque pixel de l'image aux différentes classes thématiques dans la scène). soit sur une représentation statistique extraite des mesures physiques en sortie du capteur, et qui caractérise la fréquence d'occurrence des valeurs mesurées pour chaque pixel [Pagoulatos *et al.*, 2000].

Le mode de représentation probabiliste est effectué au moyen des distributions de probabilités sur l'ensemble des classes où chaque pixel (dans chaque espace de primitive) est associé à une valeur de probabilité caractérisant l'occurrence de ce pixel dans la classe considérée. Ce mode de représentation probabiliste permet de modéliser l'incertitude inhérente aux connaissances disponibles.

Les méthodes bayésiennes, basées sur la représentation probabiliste, sont utilisées dans plusieurs travaux d'interprétation de scène au niveau pixelique. *L. Bruzzone* et *D. F. Prieto* [Rucklidge, 1996] ont proposé une approche pour la détection de changement automatique. La technique proposée est basée sur l'hypothèse que la densité de probabilité  $Pr(x)$  calculée sur les valeurs de niveau de gris de pixels dans l'image de différence, peut être modélisée comme une densité d'un mélange de deux classes : classe de pixels non-modifiés et classe de pixels modifiés. Ces deux classes sont supposées avoir des densités de probabilité gaussiennes dont les paramètres sont estimés par l'approche de maximisation d'espérance (*EM*). *A. Villa et al.* [Rao, 2019] ont utilisé l'analyse discriminante en composantes indépendantes « *ICDA* : Independent Component Discriminant Analysis » pour la classification pixelique en télédétection. Les fonctions de densité de probabilités de chaque composante indépendante sont estimées en utilisant la méthode d'estimation par noyau « *KDE* : Kernel Density Estimation » et enfin, la règle de Bayes est appliquée pour la décision de classification finale. L'algorithme de maximum de vraisemblance (*ML*) a été largement utilisé pour la classification thématique des images surtout dans le domaine de la télédétection [Press et al., 2007]. *M. Torma* [Brown, 1992] a essayé d'améliorer le taux de reconnaissance dans les zones naturelles en utilisant une méthode de fusion multisources. Les images ont été d'abord classifiées en utilisant l'algorithme de maximum de vraisemblance et les résultats de classification ont été fusionnés à l'aide de différentes méthodes de fusion basées sur le théorème de *Bayes*.

L'appartenance d'un pixel à une classe donnée dépend de l'occurrence statistique de la valeur numérique mesurée pour la classe considérée. Ceci rend les méthodes basées sur la représentation probabiliste très sensibles au bruit et incapables de discriminer les classes dans un contexte où ces classes sont très difficiles à discriminer (c'est-à-dire avec la présence d'un fort chevauchement des valeurs observées pour les différentes classes). De plus, la représentation probabiliste ne permet pas d'intégrer d'une façon flexible, les connaissances de type descriptif de l'expert qui sont, par nature, ambiguës et liées au contenu sémantique de l'image. Afin de remédier à ces inconvénients liés à la représentation probabiliste, d'autres modes de représentation des connaissances ont été utilisés.

*F. Ludic* a développé un outil de classification pixelique d'images "*FuII* : Fuzzy Reasoning applied to Image Intelligence". Cet outil est basé sur la représentation des connaissances selon les théories des ensembles flous et des croyances de Dempster Shafer. La représentation floue des connaissances est obtenue au travers de fonctions d'appartenance aux formes prédéfinies : gaussienne, triangulaire, trapézoïdale ou la forme de l'histogramme normalisé. Les paramètres de ces fonctions sont estimés à partir des échantillons sélectionnés par l'expert. Les fonctions de masse sont ensuite calculées à partir des fonctions d'appartenance en utilisant des méthodes de transformations telles que la normalisation des valeurs d'appartenance. Le but de cet outil est de comparer plusieurs opérateurs de fusion et règles de décision dans le cadre de la classification d'images appliquée à la cartographie de la couverture du sol. La sélection par l'expert, des échantillons considérés comme totalement représentatifs des différentes classes dans la scène et ensuite l'utilisation de ces échantillons pour l'estimation des paramètres des fonctions d'appartenance constituent l'inconvénient majeur de cette méthode. *L. Roux* and *J. Desachy* [Marquardt, 1963] ont présenté une méthode de fusion d'informations multi-sources pour la classification d'images

satellitaires. Les principales caractéristiques de cette méthode sont l'utilisation de la théorie des possibilités pour gérer l'incertitude liée à la classification des pixels et la possibilité de fusionner les sources numériques (les bandes spectrales de l'image). Les distributions de possibilités sont simplement estimées par la normalisation d'histogrammes des données d'apprentissage et ceci dans chaque bande spectrale. Cette méthode a été appliquée sur des images du satellite Landsat avec un taux de reconnaissance de l'ordre de 78%. Ce résultat, très modeste, est dû à la négligence du contexte spatial des pixels à classifier ainsi que la forte dépendance statistique des données d'apprentissage sélectionnées par l'expert. T. Nakashima et al [Ishibuchi et Nakashima, 2001] ont proposé une méthode de classification basée sur des règles floues qui permettent de mettre l'accent sur une ou plusieurs classes. Ils ont considéré le problème de classification comme un problème de minimisation des coûts et ont employé la notion de pondération dans le processus d'apprentissage. Les règles floues sont générées en tenant compte des pondérations des données d'apprentissage, et en utilisant des ensembles flous triangulaires. Cette méthode a été évaluée sur plusieurs applications de traitement d'image, telles que le diagnostic du cancer du sein à partir d'images mammographiques. Le taux de reconnaissances était de l'ordre de 94% (dans le cas d'images mammographiques) et de l'ordre de 64% (dans le cas de la classification des images du satellite Landsat, base de données STATLOG). L'intervention importante de l'expert tant au niveau de la construction des règles floues qu'au niveau de pondération constitue un inconvénient essentiel de cette méthode. De plus, la négligence du contexte spatiale des pixels ne permet pas la bonne discrimination des classes ayant un fort chevauchement (comme c'est le cas pour les données STATLOG). Farah et al. [Meurée, 2013] ont proposé une approche semi-automatique pour l'interprétation des images, en tenant compte des imperfections qui accompagnent ce processus. Cette approche comporte trois modules. Le premier module est un module d'apprentissage basé sur l'évaluation de trois méthodes de fusion (une méthode probabiliste, une méthode possibiliste et une méthode reposant sur la théorie des croyances) appliquées aux images satellitaires. Le deuxième module vise à déterminer la meilleure méthode de fusion en utilisant une base de règles et un raisonnement à base de cas (*CBR*). Le dernier module est consacré à la fusion d'images multi-capteurs en utilisant la meilleure méthode de fusion récupérée par le *CBR*. Les distributions des probabilités (respectivement, des possibilités et celles des masses de croyance) sont estimées par la méthode de l'estimation à base de noyau « KDE : Kernel Density Estimation » (respectivement, par l'algorithme de possibilistic C-means (PCM) ) à partir des régions d'intérêt choisies par l'expert. Cette approche a été validée sur un ensemble d'images optiques SPOT-4 et des images radar ERS-2 représentant une région tunisienne centrale. Nous constatons dans cette approche l'utilisation d'une méthode non-paramétrique KDE pour l'estimation des distributions de probabilités à partir d'un ensemble limité d'échantillons sélectionnés par l'expert. Cependant, cette approche proposée dans [Meurée, 2013] présente des limitations liées à la construction d'une base des règles ainsi qu'à la dépendance des régions d'intérêt choisies par l'expert pour l'estimation des distributions (probabiliste, possibiliste et celle des croyances) caractérisant les différentes classes dans la scène. Le contexte spatial est aussi négligé dans cette méthode d'interprétation de scène. D'une manière générale, l'utilisation des représentations floue et possibiliste dans les méthodes proposées pour l'identification du contenu informationnel et l'interprétation de scène au niveau pixelique permet, d'un côté de gérer l'attribution des pixels

aux différentes classes par rapport à l'interprétation de scène probabiliste et d'un autre côté, d'intégrer les connaissances d'expert liées au contenu sémantique de l'image. En revanche, ces méthodes opèrent sur des ensembles limités d'échantillons d'apprentissage et qui sont considérés comme représentatifs des différentes classes dans la scène. De plus, le contexte spatial des pixels permettant de réduire l'incertitude liée à la classification de ces pixels n'est pas exploité dans la majorité de ces méthodes. En effet, ces méthodes ne fournissent pas les mécanismes qui permettent d'évaluer l'incertitude liée à la classification des pixels.

#### 4.2.2 Connaissances du niveau sémantique

Ce niveau d'interprétation porte sur l'identification du contenu informationnel des entités homogènes (régions) formées par des pixels connectés qui ont des caractéristiques similaires telles que les caractéristiques colorimétriques, texturales ou morphologiques. Généralement, le processus d'interprétation de scène au niveau région commence par une phase d'analyse basée sur des techniques de segmentation des images disponibles afin d'extraire les régions homogènes de la scène.

Les connaissances *a priori* liées aux caractéristiques des régions permettent généralement d'exprimer l'apparence visuelle de chaque classe de régions. Cela peut se traduire par des termes linguistiques ou des descripteurs qualitatifs qui peuvent être représentés par des fonctions d'appartenance ou par la délimitation des échantillons considérés comme représentatifs des régions à identifier. Ces échantillons servent soit à estimer des distributions (probabiliste, d'appartenance, possibiliste ou des masses de croyance) caractérisant les régions d'intérêt [Meurée, 2013], soit à extraire des caractéristiques textuelles telles que des coefficients d'homogénéité basés sur la matrice de cooccurrence (*GLCM*) [Montagnat, 1999], etc.

F. Liu et al [Pelizzari *et al.*, 1989] ont proposé une méthode de segmentation d'images pour l'identification du contenu des plaques d'athérosclérose dans l'être vivant. Cette méthode est composée de deux parties. Dans la première partie, des cartes de probabilités sont générées en se basant sur des réseaux bayésiens. A chaque pixel de ces cartes, une valeur de probabilité d'appartenance à une classe donnée est attribuée individuellement. Les densités de probabilités conditionnelles sont estimées à partir d'un ensemble limité d'échantillons d'apprentissage par le biais d'une estimation basée sur la méthode à base de noyau « KDE : Kernel Density Estimation ». Dans la seconde partie, ces cartes de probabilités et un modèle basé sur les champs de Markov (*MRF*) sont combinés afin d'exploiter une règle de décision basée sur le maximum *a posteriori* (*MAP*) et ceci afin d'attribuer une étiquette de classe à chaque région homogène. Dans cette méthode, nous constatons l'utilisation de la méthode *KDE* pour l'estimation des distributions de probabilités à partir d'un ensemble limité d'échantillons d'apprentissage ainsi que l'exploitation du contexte spatial afin de réduire l'incertitude liée à la classification des régions détectées. L'estimation à partir d'un ensemble limité d'échantillons constitue une contrainte de cette méthode. De plus, les résultats obtenus par l'utilisation des champs de Markov dépendent fortement des conditions initiales [Delhay, 2006].

F. Huet et S. Philipp ont aussi proposé un système de fusion d'images. Dans un premier temps, l'image analysée est segmentée par plusieurs méthodes de segmentation. Ensuite, chaque région détectée dans les images segmentées est interprétée en lui attribuant une valeur d'appar-

tenance à une classe donnée. Ces valeurs d'appartenances sont estimées à partir des données d'apprentissage et en utilisant l'algorithme d'apprentissage SVM possibiliste. Les images interprétées sont ensuite fusionnées par un opérateur de fusion de la théorie des ensembles flous. Plusieurs opérateurs de fusion ont été comparés. Cette méthode présente l'intérêt d'utiliser la représentation floue ainsi que la fusion multi-sources des connaissances (plusieurs images segmentées) afin d'améliorer les résultats de la segmentation. Cependant, cette méthode dépend d'un ensemble limité de d'échantillons d'apprentissage pour l'estimation des valeurs d'appartenance des régions détectées. De plus, aucune évaluation de l'incertitude liée à la classification de ces régions n'a été réalisée dans ce système.

W. Eziddin a présenté une approche de segmentation d'images par diffusion des connaissances dans le domaine possibiliste, approche qui a pour objectif de détecter des tumeurs en imagerie mammographique. Un aspect important du raisonnement humain a été modélisé dans ce processus de classification des pixels en intégrant de manière itérative, l'information issue du contexte spatial de ces pixels. En outre, cette approche permet d'évaluer les valeurs d'appartenance des pixels afin d'affiner les résultats de segmentation. Cette approche peut être essentiellement résumée en quatre étapes (Figure 4.1) :

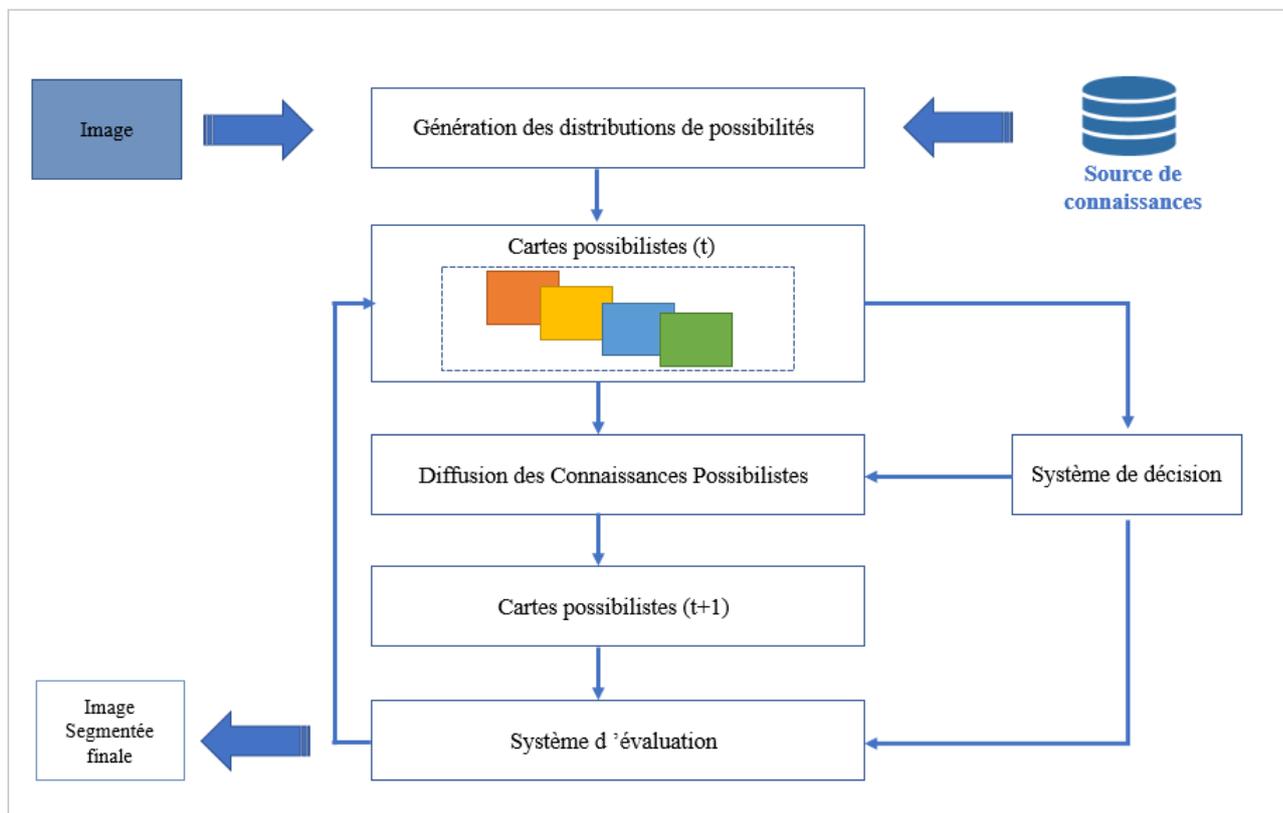


FIGURE 4.1 – Méthode de segmentation d'image par diffusion des connaissances possibilistes

- L'initialisation de l'approche qui est basée sur des connaissances descriptives exprimées par l'expert. Ces connaissances sont représentées par des distributions de possibilités ayant des formes prédéfinies et associées aux différentes classes thématiques présentes dans l'image. La projection de ces connaissances sur l'image initiale permet de générer des images appelées « cartes possibilistes » représentant l'appartenance de chaque pixel de l'image initiale aux

différentes classes thématiques.

- Le système de décision qui a pour objectif d’attribuer les pixels à une classe thématique donnée avec un fort degré de certitude, à cette classe, et ceci selon la règle de décision adoptée. Ces pixels classifiés avec une forte certitude sont appelés germes possibilistes et forment les connaissances extraites à chaque itération. Les pixels qui ne sont pas classés durant cette itération sont considérés comme appartenant à une classe nommée « rejet ». Cette classe est une classe de rejet de classification temporaire ; en effet, l’appartenance aux différentes classes, des pixels qui y sont rangés, sera réévaluée durant l’itération suivante
- Le système de diffusion des connaissances possibilistes se charge ensuite de diffuser itérativement dans le voisinage des pixels les connaissances extraites de l’image (i.e. germes possibilistes), dans l’espace des connaissances possibilistes. Cette étape aboutit à la mise à jour des cartes possibilistes qui seront utilisées à l’itération suivante. Deux modes d’intégration des germes possibilistes (i.e. point d’encrage des classes) ont été proposés : statique et dynamique. De même, en se basant sur le principe du filtre de Nagao, deux stratégies de diffusion ont été proposées : la méthode de diffusion classe/classe et la diffusion croisée. Dans la première stratégie, le choix de la clique de diffusion optimale aboutit à la sélection de différentes cliques en fonction de la carte possibiliste considérée. En revanche, pour la stratégie de diffusion croisée, une même clique est appliquée pour la diffusion des connaissances sur toutes les cartes. Ces deux stratégies de diffusion des connaissances, ainsi que les deux modes d’intégration des germes ont été évaluées de manière qualitative et quantitative.
- Le système d’évaluation qui permet, d’un côté d’évaluer l’incertitude liée à la classification des pixels afin d’enrichir l’ensemble des germes possibilistes et d’un autre côté, d’évaluer la nécessité de poursuivre le processus itératif de diffusion possibiliste des connaissances.

Les méthodes d’interprétation proposées au niveau région, ont de plus en plus tendance à utiliser les représentations floue ou possibiliste dans le processus d’interprétation de scène et ceci dans un contexte de plusieurs sources des connaissances : contexte spatial des pixels ou des régions, connaissances d’expert, résultats de plusieurs méthodes de segmentation, etc. Cette tendance est due au besoin croissant d’intégrer des connaissances *a priori* d’une part, et de manipuler explicitement les imperfections liées aux connaissances d’autre part. Notons que d’une manière générale, les méthodes proposées dans la littérature suivent une démarche « ascendante » du niveau sémantique le plus bas (niveau sous-pixelique, ou pixelique) vers le niveau objet. Aucune méthode ne propose une démarche descendante permettant de déterminer, pour les régions détectées, les caractéristiques fondamentales du type composition/contenu global des classes thématiques de base. Nous proposons d’investiguer une telle démarche descendante d’interprétation dans le cadre du recalage de notre travail.

### 4.3 Description des classes sémantiques

La définition des classes des images à recalcer est une information importante pour notre approche. Dans ce cadre nous distinguons deux contextes : supervisé et non supervisé. Dans un contexte supervisé, les connaissances préalables concernant le contenu sémantique des images sont supposées disponibles. Les cartes sémantiques des images source et cible sont obtenues

directement par *un expert*. En revanche, dans un contexte non supervisé, aucune connaissance préalable n'est disponible concernant le contenu sémantique des images ; ainsi, cette connaissance sémantique devrait être «extraite» en utilisant certaines approches de clustering ce qui fait l'objet d'une contribution de notre travail, où nous appliquons une méthode de classification non supervisée (*FCM multi-centroïdes*) permettant d'avoir une caractérisation des classes présentes dans une image servira la phase de projection permettant la génération des cartes de possibilités.

#### Pourquoi l'algorithme *FCM Multi-centroïde* pour la classification non supervisé ?

Nous rappelons que notre choix est basé sur deux critères ; complexité temporelle optimale et bonne gestion de l'ambiguïté. L'étude réalisée (*Section 3.9*) nous a permis de choisir cet algorithme. Il assure une meilleure caractérisation des caractérisations des classes présentes dans une image par rapport à l'algorithme *FCM standard*. Il présente l'avantage d'exploiter les images caractéristiques d'une nouvelle façon moins couteuse en termes de complexité temporelle où les centroïdes obtenus à l'issue de l'application de l'*algorithme FCM* ne sont pas forcément tous considérés.

En effet, l'algorithme proposé exploite le fait qu'une image caractéristique peut apporter une information supplémentaire une classe au minimum. Ainsi, la prise en compte de tous les centroïdes identifiés peut ne pas être intéressante soit à cause d'une redondance ou à cause d'une dissimilarité. L'application de l'algorithme FCM sur chaque image caractéristique est beaucoup moins couteuse que de l'exécuter sur un grand ensemble d'images. Finalement, la fusion des fonctions d'appartenances permet d'enlever l'ambiguïté sur l'appartenance des pixels.

La figure 4.2 illustre le modèle de classification utilisé dont l'objectif est d'obtenir une description précise des classes sémantiques des deux images à recalcr.

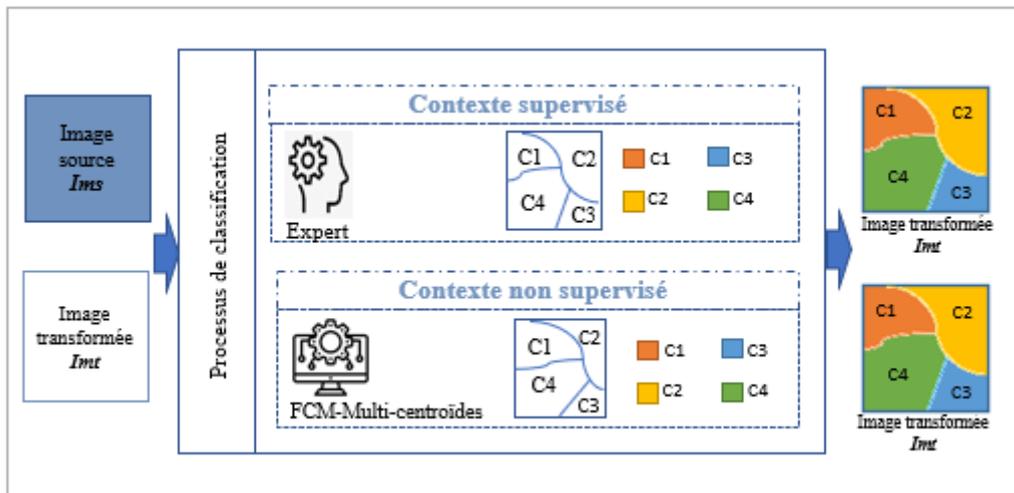


FIGURE 4.2 – Modélisation du processus de classification possibiliste

## 4.4 Fusion de connaissances

La définition des classes sémantique va servir la phase principale (phase de génération des cartes de possibilités)de notre approche de recalage géométrique possibiliste proposée. Il s'agit

d'appliquer un processus de projection des informations au niveau sémantique sur les bases de connaissances au niveau pixelique afin d'obtenir une nouvelle base de connaissances semi-sémantique.

La figure 4.3 présente le processus de fusion des deux bases de connaissances issues des images à recaler. Cette base est plus riche et plus précise en termes d'information.

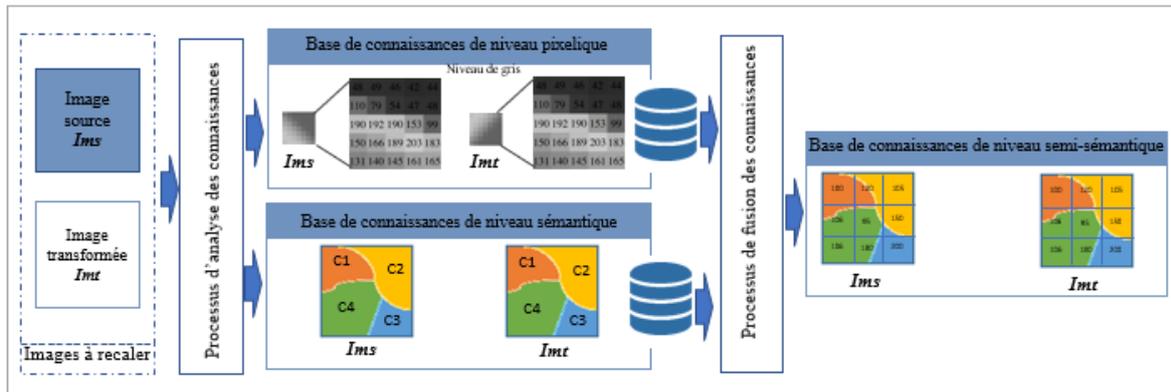


FIGURE 4.3 – Base de connaissances semi-sémantique : Fusion des connaissances des niveaux pixelique et sémantique

La phase de projection consiste à l'application d'une transformation de la base de connaissances afin d'obtenir des cartes possibilistes où chaque carte représente les valeurs de possibilité pour les pixels des différentes images d'appartenance à une carte sémantique donnée. Cette transformation divise la connaissance du niveau de gris de chaque image considérée en  $M$  images semi-sémantiques (i.e., cartes possibilistes) où  $M$  est le nombre de cartes thématiques (représentant des contenus thématiques) existant dans la scène analysée en se basant sur la description des classes (Contexte supervisé et/ou non supervisé).

Il est intéressant de noter que dans chaque carte possibiliste, «l'énorme quantité» de connaissances incluses dans différentes images est réduite, à travers cette projection de connaissances, dans la connaissance semi-sémantique concernant une carte sémantique donnée. Outre le fait de «focaliser les connaissances», cette transformation offre un avantage important que le recalage d'images peut être effectué tout en concentrant les efforts sur des caractéristiques liées à chaque carte sémantique incluse dans la scène analysée. En conséquence, une réduction importante du temps de calcul et le maintien de performances de haut niveau (en termes de réduction des faux amers, de moindre sensibilité au bruit et de meilleure précision) sont attendus de cette approche. La figure 4.4 illustre le processus de génération des cartes de possibilités en fonction du contenu sémantique des images.

#### 4.4.1 Principe

En utilisant les mécanismes de raisonnement possibiliste spatial, l'approche proposée intègre de manière itérative, l'information issue du contexte spatial des pixels afin d'enrichir la base d'apprentissage initiale des différentes classes. En effet, l'exploitation du contexte spatial des pixels permet l'extraction de nouveaux pixels ayant une possibilité d'appartenance à une classe thématique donnée avec un une forte valeur de degré de certitude, et ceci selon la règle de

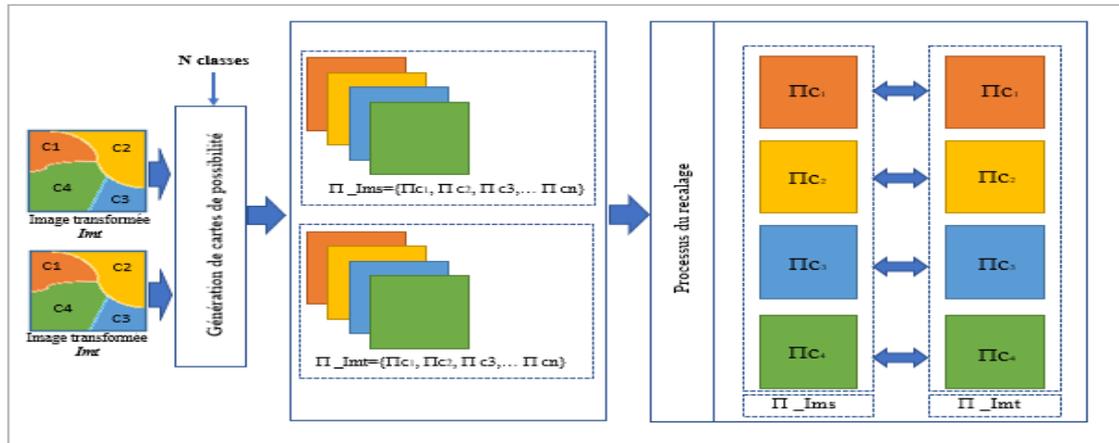


FIGURE 4.4 – Extension de l'espace de représentation

sélection (décision) adoptée.

Les pixels sélectionnés à chaque itération (appelés germes possibilistes) sont ajoutés à la base d'apprentissage des différentes classes. Notons que la base d'apprentissage initiale est formée par les zones d'apprentissage délimitées par un expert ou bien par un système de classification non supervisé.

Soit  $\Psi = C_1, C_2, \dots, C_M$  un ensemble exhaustif et exclusif de  $M$  classes thématiques contenues dans les images à recaler et soit  $B_0 = Z_{0,1}, Z_{0,2}, \dots, Z_{0,M}$  un ensemble comportant des zones d'apprentissage initiales pour les différentes classes thématiques prédéfinies, zones délimitées des images  $I_{ms}$  et  $I_{mt}$ .

Nous considérons une approche itérative dans laquelle chaque itération nommée  $I_t$  est composée de trois étapes principales :

- Estimation des distributions de possibilités à partir de l'ensemble  $B = \bigcup_{k=0}^t B_k$  de zones d'apprentissage : cette estimation des distributions de possibilités est basée sur les transformations des distributions de probabilités vers des distributions de possibilités,
- La projection des images  $I_{ms}$  et  $I_{mt}$  sur ces distributions de possibilités permettant de générer les ensembles d'images appelées « cartes possibilistes » ( $C_{PI,Cm}, m = 1, \dots, M$ ) qui représentent la possibilité d'appartenance de chaque pixel de l'image initiale  $I$  aux différentes classes thématiques de  $\Psi$ ,
- L'exploitation des cartes possibilistes ainsi que des informations spatiales par le biais d'un système de raisonnement possibiliste spatial afin de sélectionner de nouveaux germes possibilistes pour chacune des classes thématiques. Ces germes sont ajoutés à l'ensemble  $B = \bigcup_{k=0}^{t+1} B_k$  pour l'estimation des distributions de possibilités à l'itération suivante «  $t+1$  ».

Le processus d'enrichissement des zones d'apprentissage est ensuite répété itérativement jusqu'à ce qu'aucun germe ne puisse être rajouté à l'ensemble des zones d'apprentissage.

#### 4.4.2 Estimation des distributions de possibilités

Nous rappelons que la description des classes thématiques est fournie par un expert ou bien par un système en classification non supervisé, il s'agit des zones d'apprentissage utilisées

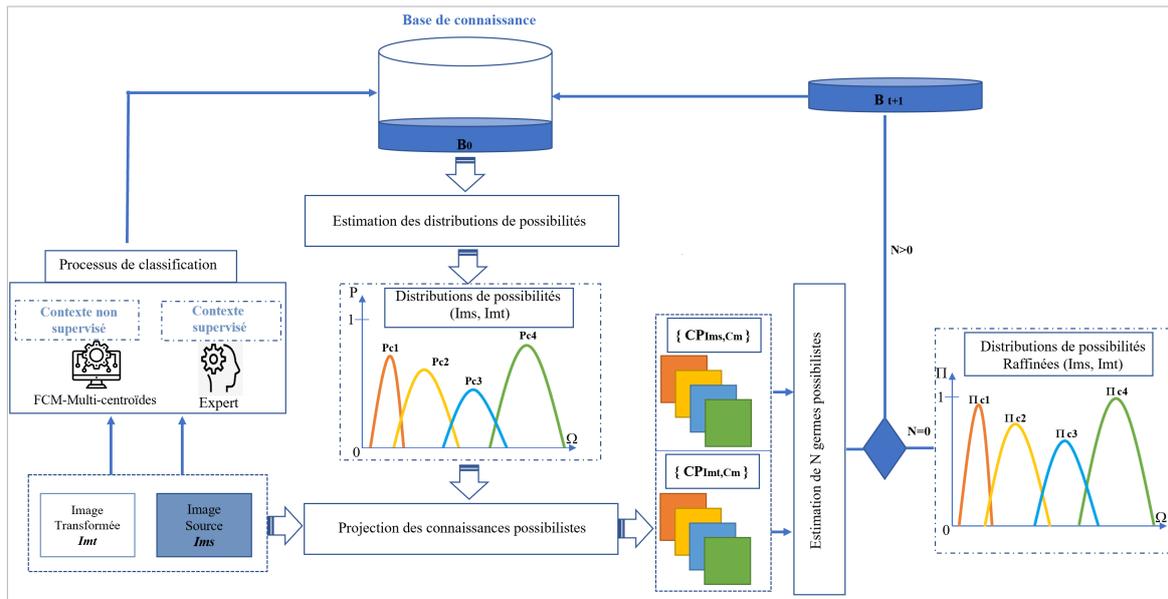


FIGURE 4.5 – Approche proposée pour la génération des cartes possibilistes

pour l'estimation des distributions de possibilités aux différentes classes thématiques de notre processus de projection des connaissances.

La méthode d'estimation proposée comporte deux étapes :

- ✓ **Étape 1** : Application de la méthode d'estimation par noyau *KDE* (Kernel Density Estimation)

C'est une méthode non-paramétrique d'estimation de la densité de probabilité, elle est utilisée pour l'estimation des densités de probabilités des classes concernées à partir des zones d'apprentissages [107].

#### *Pourquoi cette méthode ?*

La méthode KDE est particulièrement utilisée dans le cas où les données statistiques sont limitées (Comme dans notre cas). De plus, cette méthode, non-paramétrique, permet d'estimer la forme de la distribution de probabilités suivie par les données statistiques sans imposer d'allure à cette distribution. Bien souvent, le noyau utilisé dans cette méthode  $K$  est choisi comme la densité d'une fonction gaussienne standard (espérance nulle et variance unitaire) (Equation (4.1)). Généralement, le choix du noyau  $K$  est peu influent sur l'estimation des distributions de probabilités, mais il n'en est pas de même pour la largeur du noyau  $L$  (le paramètre de lissage). En effet, une valeur trop faible de  $L$  provoque l'apparition de détails artificiels apparaissant sur la distribution de probabilités estimée. Pour une valeur de  $L$  trop grande, la majorité des caractéristiques est au contraire effacée. Le choix de  $L$  est donc une question centrale dans l'estimation de distributions de probabilités.

$$E(x) = \frac{1}{NL} \sum_{i=1}^N K\left(\frac{x - x_i}{L}\right) \quad (4.1)$$

Avec  $x$  une variable aléatoire prenant ses valeurs dans l'univers de discours  $W = x_1, x_2, \dots, x_N$  et  $E(x)$  est la valeur estimée de la densité de probabilité à  $x$ .

- ✓ **Étape 2** : Transformation des densités en des distributions de possibilités

Nous utilisons la transformation de probabilités-possibilités symétrique proposée par Dubois-Prade pour la transformation des densités de probabilités en des distributions de possibilités. La figure ?? présente les étapes du processus d'estimation des distributions de possibilités

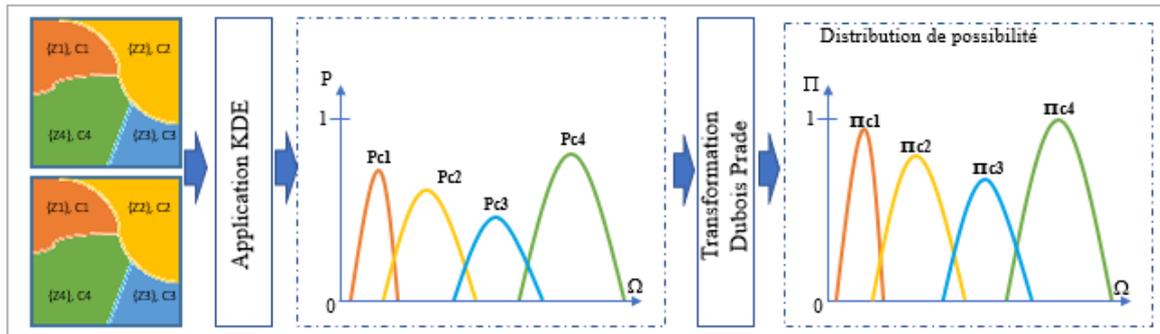


FIGURE 4.6 – Processus d'estimation des distributions de possibilités

#### 4.4.3 Fonctions de masse pour la fusion des connaissances

L'étape d'estimation des distributions de possibilités aboutit à la construction de d'un ensemble de distributions de possibilités nommée  $M$  (associées aux  $M$  classes thématiques)  $\Psi = C_1, C_2, \dots, C_M$  présentes dans les images à recaler) :

$$\pi_{C_m} : \Omega \rightarrow [0, 1] \quad (4.2)$$

$$x \rightarrow \pi_{C_m}(x)$$

où  $x$  désigne la primitive observée.  $\pi_{C_m}(x(P))$  associe chaque pixel  $P \in I$ , ayant une valeur de primitive  $x(P) \in \Omega$ , à un degré de possibilité d'être de la classe  $C_m, m = 1, \dots, M$ . Etant données les images  $Im_s$  et  $Im_t$  de taille  $A \times W$ , l'application de ces distributions de possibilités sur cette image permet la projection des connaissances sur les classes thématiques, et ainsi, l'obtention de  $M$  images de taille  $A \times W$  appelées cartes possibilistes  $CP_{I,C_m}, m = 1, \dots, M$  pour chacune des images à recaler. :

$$CP_{I,C_m}(i, j) = \pi_{C_m}(x(P(i, j))), i = 1, \dots, A; j = 1, \dots, W \quad (4.3)$$

Chaque carte possibiliste  $CP_{I,C_m}, m = 1, \dots, M$  a les mêmes dimensions que l'image d'origine (respectivement  $Im_s$  et  $Im_t$ ), et comporte les degrés de possibilités pour tous les pixels de l'image d'origine, d'être de la classe  $C_m$ . Cette phase de la projection des connaissances possibilistes constitue la première étape dans tous les systèmes de classification possibilistes d'images au niveau pixelique. La deuxième étape consiste à appliquer des processus de décision sur les  $M$  cartes possibilistes afin de former l'image thématique où chaque pixel sera associé à une, et une seule, des classes thématiques données. Nous rappelons que les connaissances sur les classes thématiques sont fournies par un expert dans le contexte supervisé de notre approche ou par un système de classification non supervisé (FCM multi centroïde) dans un contexte non supervisé.

La figure 4.7 illustre le processus de projection de notre approche proposée.

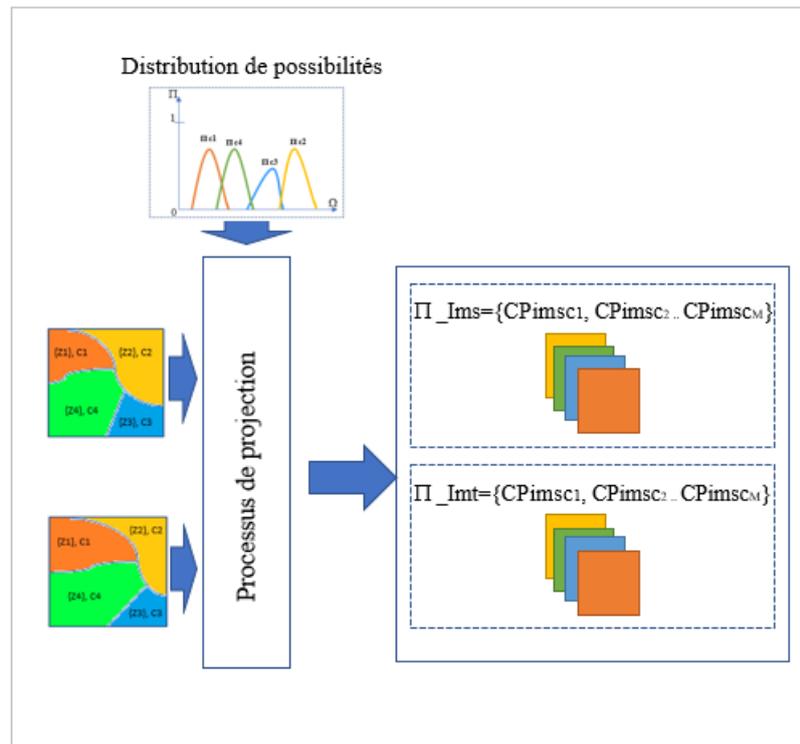


FIGURE 4.7 – Processus de projection des connaissance possibilistes

## 4.5 Processus du recalage géométrique possibiliste proposé

Dans cette section nous présentons le processus de l'approche géométrique du recalage proposé qui prend en entrée l'ensemble des cartes de possibilités obtenues à partir du processus de projection des connaissances (section 3.8 et 3.9).

En effet, la plupart des méthodes de recalage de l'approche géométrique souffre du nombre important des faux amers causés par l'ambiguïté les connaissances lors de la mise en correspondance des primitives.

De cet effet, dans ce travail, nous proposons une approche qui est basée sur des concepts de raisonnement humain afin de conduire le processus de recalage vers un aspect sémantique permettant de la réduction du degré d'incertitude afin d'avoir des meilleurs résultats de recalage.

L'idée principale de l'approche proposée consiste à appliquer les phases de recalage géométrique classique sur l'ensemble des cartes obtenues par la phase de projection des connaissances en non pas sur toute l'image. En fait, si la scène considérée comporte  $\sim M$  classes (pour lesquelles nous supposons la connaissance de leurs distributions de possibilités associées), alors, le processus de projection de connaissances semi-sémantique consiste à transformer chaque image (i.e., les images source et cible) en  $M$  cartes possibilistes, où chaque carte est formée par des valeurs de possibilités de carte données. Ce processus de transformation des connaissances (des caractéristiques basées sur le niveau de gris au niveau de représentation semi-sémantique possibiliste)

est, d'une manière ou d'une autre, supposé imiter du processus de focalisation de l'attention visuelle de l'être humain. De plus, au lieu de conduire le processus de recalage sur une paire d'images, cette transformation permet de conduire le processus de recalage autant de fois que le nombre de cartes sémantiques considérées.

Un avantage majeur de l'approche de projection des connaissances proposée consiste à minimiser le risque de conflit, lors du processus d'appariement, entre les caractéristiques extraites des images source et cible.

L'approche de recalage géométrique possibiliste proposée comporte quatre phases principale :

1. Détection des primitives au niveau de chaque carte possibilistes à l'aide d'un détecteur ;
2. Description des primitives extraites de l'ensemble des cartes possibilistes en utilisant un descripteur de primitives ;
3. Mise en correspondance des cartes possibilistes issues des images source et cible ;
4. Fusion des recalages partiels résultant.

Les phases du recalage possibiliste proposé est illustré dans la figure 4.8

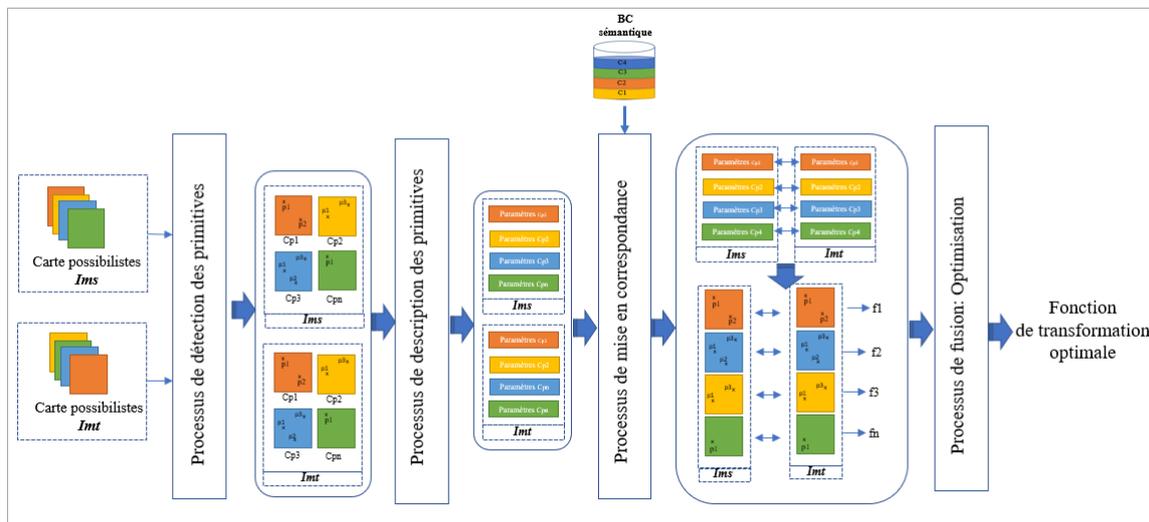


FIGURE 4.8 – Schéma global de l'approche de recalage possibiliste proposée

Nous détaillons dans ce qui suit les méthodes utilisées pour chaque phase de notre approche de recalage possibiliste proposée.

#### 4.5.1 Extraction des primitives

Le choix d'un type de primitives d'images à détecter dépend de plusieurs facteurs. Ainsi, les caractéristiques du capteur sont à prendre en compte (i.e., choix de la primitive la moins sensible possible au bruit caractéristique du capteur).

En fait, le choix de la mesure de similarité est à faire en fonction du type et de la quantité de structures présentes dans l'image (lignes, cercles, etc.). Souvent, les méthodes de détection de primitives image cherchent sur toute l'image des « candidats » pour ensuite décider si l'information détectée est une primitive image du type souhaité ou pas. Les primitives résultantes sont des régions de l'image qui forment des points isolés, des courbes continues (point connectés) ou des

régions connectées. La caractéristique la plus importante d'un détecteur de primitive image est la répétabilité, c'est-à-dire, sa capacité pour détecter la même primitive dans plusieurs images de la même scène. Un grand nombre d'algorithmes de détection ont été développés. Ces détecteurs varient selon le type de primitive à détecter, la complexité de calcul et la répétabilité. Au final, la qualité du recalage dépend des performances du détecteur de primitives.

Pour notre travail nous avons surmonter les limites des méthodes de détection de primitives par l'exploitation de l'aspect sémantique des images à recaler en utilisant des distributions de possibilités permettant l'obtention d'un ensemble de cartes de possibilités pour chaque image (source et cible).

De ce fait, nous allons considérer l'ensemble de cartes de possibilités obtenues par la phase de projection comme données d'entrées du processus de détection de primitives.

#### 4.5.2 État de l'art sur les méthodes d'extraction des primitives

Une étude bibliographique qui a été réalisé afin de justifier notre choix de détecteur. Nous organisons notre étude bibliographique selon huit catégories de méthodes telles qu'elles sont définies par Delalandre dans [Uttama *et al.*, 2005], où il fournit un état de l'art sur l'extraction de primitives graphiques.

- **Méthodes basées sur la détection de contour :** Cette méthode se base sur la squelettisation et elle se réalise en deux méthodes qui peuvent être distinctes ou fusionnées ; il s'agit donc de détecter les contours et de procéder au chaînage de ces points contours [Uttama *et al.*, 2005].
- **Méthodes basées sur la squelettisation :**
  - Méthodes basées sur les parcours de formes,
  - Méthodes basées sur la décomposition en plages,
  - Méthodes basées sur la segmentation en régions,
  - Méthodes basées sur le sous-échantillonnage,
  - Méthodes basées sur les graphes de composantes,
  - Méthodes basées sur les transformées de Hough ou de Radon.

Nous mettons l'accent sur un ensemble de critères pour justifier notre choix de la méthode à utiliser dans notre approche de recalage.

- Est-elle invariante à la fonction de transformation (Changement d'échelle, rotation, ... ) ?
- Est-elle sensible au bruit ?
- Quel type de représentation permet-elle d'obtenir ?

L'objectif de cette étude n'est pas d'évaluer toutes ces méthodes, mais plutôt d'en décrire les principes de fonctionnements et d'en synthétiser les propriétés qui nous semblent intéressantes, afin de pouvoir porter notre choix par la suite sur la catégorie de méthodes la plus adaptée à notre travail.

Le table 4.1 présente une récapitulation de l'étude réalisée en se basant sur les critères soulignés.

TABLEAU 4.1 – Attributs de la qualité de l'information

Méthodes basées sur la détection de contour	
<b>Représentation</b>	Contours
<b>Avantages</b>	- Représentation exacte des symboles - Peu sensibles aux bruits
<b>Inconvénients</b>	- Ne permettent pas de décrire les structures des formes, telles que les jonctions, et sont donc faiblement informatives vis-à-vis de la topologie de l'image.
<b>Références</b>	[Fjørtoft, 1999], [Pflug et Busch, 2012]
Méthodes basées sur la squelettisation	
<b>Représentation</b>	Squelettisation
<b>Avantages</b>	- Bonne approximation des axes médians Invariantes au changement d'orientation.
<b>Inconvénients</b>	- Problème des distorsions de jonctions : rend la construction du graphe de squelette complexe et ambiguë. - Peu adaptées aux formes pleines. - Sensibles au bruit.
<b>Références</b>	[Leborgne, 2016]
Méthodes basées sur les parcours de formes	
<b>Représentation</b>	Squelettes ou contours
<b>Avantages</b>	- Primitives à base de vecteurs : primitives sémantiquement fortes. - Permettent une bonne détection des jonctions. - Peu sensibles aux bruits mais...
<b>Inconvénients</b>	Dans certains cas de bruit fort, à utiliser avec précautions. Non adaptées aux formes pleines.
<b>Références</b>	[Lavric <i>et al.</i> , 2020]
Méthodes basées sur la décomposition en plages	
<b>Représentation</b>	Squelettes ou contours
<b>Avantages</b>	- Bonne détection des jonctions et des lignes. - Représentation topologiquement riche. - Faible complexité.
<b>Inconvénients</b>	- Très sensibles aux changements d'orientation. - Sensibles aux bruits impulsifs qui parsèment la forme de pixels de fond.
<b>Références</b>	[Hohweiller, 2019] [Reichert <i>et al.</i> , 2007]

Méthodes basées sur la segmentation en régions	
<b>Représentation</b>	Squelettes ou contours.
<b>Avantages</b>	<ul style="list-style-type: none"> <li>- Très bonne détection des jonctions.</li> <li>- Robustes aux bruits.</li> <li>- Robustes aux changements d'échelle et d'orientation.</li> </ul>
<b>Inconvénients</b>	
Références	[Vauclin <i>et al.</i> , 2010] [Lopes <i>et al.</i> , 2010]
Méthodes basées sur le sous-échantillonnage	
<b>Représentation</b>	Squelettes ou contours.
<b>Avantages</b>	<ul style="list-style-type: none"> <li>- Extraction de primitives graphiques variées.</li> <li>- Représentation sémantiquement riche.</li> <li>- Rapides à mettre en oeuvre.</li> </ul>
<b>Inconvénients</b>	<ul style="list-style-type: none"> <li>- Post-traitements complexe pour l'extraction de primitives.</li> <li>- Sensibles aux bruits.</li> <li>- Sensibles aux changements d'échelles et d'orientations.</li> </ul>
Références	[Betrouni, 2009] [Simmons et Voss, 1998]
Méthodes basées sur les graphes de composantes	
<b>Représentation</b>	Régions ou contours
<b>Avantages</b>	<ul style="list-style-type: none"> <li>- Propriétés similaires aux méthodes à base de détection de contours</li> </ul>
<b>Inconvénients</b>	<ul style="list-style-type: none"> <li>- Post-traitements complexe pour l'extraction de primitives.</li> <li>- Primitives extraites de types régions : composantes connexes</li> <li>- Peu adapté à notre problème.</li> </ul>
Références	[Jannin <i>et al.</i> , 2001]
Méthodes basées sur les Transformées de Hough/Radon	
<b>Représentation</b>	Squelettes ou contours
<b>Avantages</b>	<ul style="list-style-type: none"> <li>- Extraction de primitives graphiques de type vecteurs (haut niveau),</li> <li>- Bonne approximation des axes médians et bonne détection des jonctions,</li> <li>- Robustes au bruit,</li> <li>- Robustes au changement d'échelle et d'orientation.</li> </ul>
<b>Inconvénients</b>	<ul style="list-style-type: none"> <li>- Complexité en temps de calcul.</li> <li>- Complexité en espace mémoire</li> </ul>
Références	

### 4.5.3 Choix de la méthode d'extraction des primitives

L'état de l'art réalisé (section 4.5.2) prouve que les méthodes sont plus ou moins robustes aux détériorations. Nous rappelons que c'est un point important pour notre travail ; la méthode d'ex-

traction de primitives qui sera utilisée devra être relativement robuste au changement d'échelle, à la rotation, et au bruit. Il ne s'agit pas pour ce travail de tester l'efficacité de chaque méthode, ni d'évaluer le degré de dégradation des symboles, pour déterminer laquelle convient le mieux, mais bien d'étudier leurs propriétés afin d'apporter les premiers éléments de réponse.

Nous constatons que chacune de ces méthodes possède des propriétés qui lui sont propres et ne fonctionne que dans un contexte graphique particulier. Certaines catégories de méthodes se distinguent des autres par leur propriété de robustesse ou d'invariance aux changements d'échelle ou d'orientation ; d'autres se distinguent par la qualité de leur représentation, c'est-à-dire par la qualité de l'information structurelle qu'elles permettent d'obtenir en fin de traitement.

Ainsi, nous constatons que, dans la majorité des cas, ces deux aspects font l'objet d'un compromis : les méthodes qui fournissent une représentation sémantiquement riche, sont en général peu robustes au bruit et au changement d'échelle et d'orientation, et *vice versa*. Par exemple, les méthodes à base de détection de contours, ou encore les méthodes à base de segmentations en régions, sont des méthodes, qui possèdent des propriétés de robustesse et d'invariance forte, mais qui en contrepartie fournissent une représentation plutôt pauvre de point de vue aspect sémantique. En revanche, les méthodes à base de décomposition en plages ou de sous-échantillonnage, permettent d'obtenir une représentation intéressante d'un point de vue structurel, mais difficile à extraire en présence de fortes détériorations. La question "**Quel aspect privilégié ?**" pourrait alors se poser.

La réponse à la question est simple, puisque nous travaillons dans un espace de représentation de connaissance sémantique, nous n'avons pas de nécessité gestion de la qualité de la représentation des images ; par conséquent, nous choisissons les méthodes possédant les propriétés de robustesse ou d'invariance aux changements d'échelle ou d'orientation pour la détection des points dans chacune des cartes de possibilités.

#### 4.5.4 Mise en correspondance des primitives

Après avoir achevé des phases d'extraction et de description des points caractéristiques de chaque classe, nous mesurons la similarité entre des primitives des deux classes source, et cible afin de déterminer les couples d'amers homologues. Ainsi, le problème d'appariement des amers revient à déterminer la position du modèle en question (i.e., le point caractéristique et son voisinage) de l'image décalée dans l'image de référence.

Il existe plusieurs techniques de mesure de similarité dans la littérature (section 2.2.4).

Parmi ces techniques nous trouvons la corrélation croisée normalisée "*fast NCC*". Cette dernière permet d'évaluer un facteur de similarité entre le modèle et chaque point de l'image de référence. La définition basique du facteur  $\tau_{AB}$  de la corrélation croisée normalisée est donnée par l'équation Eq (4.4) :

$$\tau_{AB} = \frac{\sum_{i=1}^M \sum_{j=1}^N (I_A(i, j) - \bar{I}_A)(I_B(i, j) - \bar{I}_B)}{[\sum_{i=1}^M \sum_{j=1}^N (I_A(i, j) - \bar{I}_A(i, j))^2 \sum_{i=1}^M \sum_{j=1}^N (I_B(i, j) - \bar{I}_B(i, j))^2]^{\frac{1}{2}}} \quad (4.4)$$

Où :

A et B sont des sous ensembles respectivement de l'image de référence  $Im_s$  et le modèle de l'image décalée  $Im_t$  ;

M et N représentent les nombres de lignes et de colonnes des sous ensembles (taille du modèle).  $I_A$  et  $I_B$  donnent les niveaux de gris des sous ensembles A et B ;  $I_A(i, j)$  et  $I_B(i, j)$  indiquent la valeur moyenne des niveaux de gris des sous ensembles A et B.

Les coefficients de corrélation ( $\tau_{AB}$ ) des amers des deux images indiquent à quelle mesure les couples considérés sont homologues et peuvent former des vrais appariements.

La méthode « fast NCC » se base sur des tables d'opérations de corrélation croisée normalisée pré-calculées pour chaque image acquise, ce qui permet d'éviter des redondances de calculs. C'est pour que nous avons choisi cette méthode pour mesurer les similarités entre l'ensemble des primitives extraites des deux ensembles de cartes de possibilités des deux images à recalcr.

La difficulté de la méthode repose sur le choix du critère de prise de décision des couples homologues. L'idée intuitive est de prendre le couple ayant la plus grande mesure de corrélation en valeur absolue. Mais puisqu'il s'agit d'une information incertaine, nous pouvons mettre en place une approche possibiliste qui permet de choisir les couples d'amers homologues en tenant compte de l'incertitude de l'information. D'où la définition d'un nouveau critère possibiliste d'appariement entre amers de même classe.

La mise en correspondance des amers de la même classe réduit l'espace de recherche des points correspondants. Ainsi, le nombre de comparaisons qui détermine les paires d'amers homologues est considérablement réduit ; ce qui limite le temps d'exécution.

De plus, cette démarche nous permet d'obtenir l'ensemble des points homologues avec plus de précision puisque les amers supposés homologues seront de la même classe. Ainsi le risque d'obtention des faux appariements est considérablement réduit.

Ainsi, notre algorithme sera plus rapide et plus précis grâce à la phase de classification qui précède l'extraction des amers.

## 4.6 Estimation du modèle de transformation

Nous distinguons deux types d'estimation de modèle ;

- **L'estimation du modèle de transformation de type «Similitude non réfective» de chaque classe**

Cette transformation supporte la translation, la rotation et la mise à l'échelle. Il s'agit d'une transformation affine isotrope dont ses propriétés physiques sont invariantes *vis-à-vis* la direction. Ainsi, elle dispose de quatre degrés de liberté et nécessite deux paires de points afin d'estimer ses paramètres. Sa matrice s'écrit :

$$H = \begin{bmatrix} h_1 & h_2 & h_3 \\ -h_2 & h_1 & h_4 \end{bmatrix} \quad (4.5)$$

Les paramètres du modèle sont calculés par l'algorithme appelé "RANdom SAmple Consensus" [Prathap *et al.*, 2016]. Il s'agit d'une méthode itérative pour estimer les paramètres du modèle mathématique à partir d'un ensemble de données observées qui contient des valeurs aberrantes entre chaque paire de cartes possibilistes. Dès l'estimation des paramètres du modèle de transformation, les valeurs aberrantes dans les correspondances des amers sont éliminées. D'où la détermination du facteur d'échelle, de l'angle de rotation et du vecteur de translation du modèle affine envisagé.

- **L'estimation du modèle de transformation global**

En effectuant une fusion possibiliste entre les modèles de transformation de toutes les classes nous utilisons un opérateur possibiliste de moyenne arithmétique d'équation :

$$Matrice = \frac{\sum_{i=1}^M H_C}{M} \quad (4.6)$$

Où,  $M$  fait référence au nombre de cartes, et matrice  $H_C$  par carte.

## 4.7 Le ré-échantillonnage et interpolation de l'image cible

Nous appliquons l'interpolation bilinéaire. Elle permet de calculer la valeur d'une fonction en un point quelconque, à partir de ses 2 plus proches voisins dans chaque direction. Elle peut s'interpréter comme une succession de 2 interpolations linéaires, une dans chaque direction, mais n'est toutefois pas linéaire, à cause du terme en  $xy$ . Il s'agit d'une forme bilinéaire, qui peut se mettre sous la forme :

$$f(x, y) = ax + by + cxy + d \quad (4.7)$$

## 4.8 Conclusion

Dans ce chapitre nous avons proposé une approche qui consiste à réduire le nombre de comparaisons et d'augmenter la fiabilité de l'algorithme de recalage afin d'éliminer les faux amers. Dans le chapitre suivant nous présentons les expérimentations qui montrent les avantages obtenus par l'approche proposée.

# Expérimentation et évaluation du système de recalage possibiliste

---

## Sommaire

<b>5.1</b>	<b>Introduction</b>	<b>90</b>
<b>5.2</b>	<b>Application sur des images médicales : <u>Contexte supervisé</u></b>	<b>91</b>
<b>5.3</b>	<b>Présentation de la méthode BRISK</b>	<b>91</b>
5.3.1	Détection des primitives Scale-Space	92
5.3.2	Description des primitives	92
5.3.3	Phase de mise en correspondance des primitives	93
5.3.4	Avantages et limites de la méthode BRISK	94
5.3.5	Phase d'expérimentation	95
5.3.6	Résultats d'expérimentation	95
5.3.7	Interprétation, comparaison et évaluation	97
<b>5.4</b>	<b>Application sur des images satellites : <u>Contexte supervisé</u></b>	<b>98</b>
5.4.1	Présentation des résultats	99
5.4.1.1	Résultats d'expérimentations : Une seule transformation	101
5.4.1.2	Résultats d'expérimentations : <i>Combinaison de transformations</i>	108
5.4.2	Interprétation, comparaison et évaluation	111
<b>5.5</b>	<b>Application sur des images médicales : <u>Contexte non supervisé</u></b>	<b>112</b>
5.5.1	Présentation de l'approche	112
5.5.2	Plan d'expérimentation	113
5.5.3	Expérimentations et résultats du recalage d'images possibiliste non supervisé	114
5.5.4	Interprétation, comparaison et évaluation	117
<b>5.6</b>	<b>Conclusion</b>	<b>117</b>

---

## 5.1 Introduction

Comme mentionné précédemment, les méthodes de recalage géométrique existantes souffrent du nombre important de faux amers détectés lors de la mise en correspondance des points d'intérêt des images sources et des images cibles.

Ce nombre important de faux amers est généré suite au conflit qui peut se produire lors de détection des primitives.

Nous rappelons que les méthodes de recalage géométrique existantes se basent sur des connaissances au niveau pixelique (Le niveau le plus bas de représentation des connaissances).

Dans notre travail, nous proposons de projeter les connaissances pixelique dans un espace de représentation sémantique en utilisant la théorie des possibilités afin d'obtenir un nouvel espace de représentation des connaissances nommé "Espace de représentation semi-sémantique" combinant les connaissances au *niveau pixelique*, et les connaissances au *niveau sémantique*; ***C'est le recalage géométrique possibiliste.***

En effet, notre approche proposée englobe deux contextes : recalage possibiliste supervisé et le recalage possibiliste non supervisé.

Dans ce qui suit, nous allons détailler ces deux aspects et nous allons présenter les résultats d'expérimentations.

## 5.2 Application sur des images médicales : Contexte supervisé

La première expérience consiste à évaluer notre approche proposée à l'aide de la méthode de recalage géométrique BRISK. En fait, nous exploitons le détecteur ainsi que le descripteur de la méthode pour effectuer une étude comparative des résultats du recalage obtenus dans deux espace de représentation des connaissances différents ; pixelique ( $BRISK_{GL}$ ) : existant et sémantique  $BRISK_{\pi}$  : proposée (PBRISK).

## 5.3 Présentation de la méthode BRISK

La méthode BRISK est un détecteur et un descripteur de points d'intérêt [Wijaya *et al.*, 2022]. Cet algorithme s'attaque au problème classique de la vision par ordinateur consistant à détecter, décrire et faire correspondre les points d'intérêt de l'image sans connaissance préalable suffisante de la scène et du capteur. Contrairement aux algorithmes bien établis avec des performances élevées éprouvées comme SIFT et SURF [Brown, 1992], cet algorithme repose sur un modèle d'échantillonnage circulaire facilement configurable à partir duquel il calcule des comparaisons de luminosité afin de former une chaîne de descripteurs binaires. Les propriétés uniques de cet algorithme peuvent être utiles pour un large spectre d'applications, en particulier pour des tâches avec de fortes contraintes temps réel ou une puissance de calcul limitée. L'algorithme BRISK offre la qualité de fonctionnalités haut de gamme dans ces applications exigeantes en temps. La figure 5.1 présente les phases de la méthode BRISK.

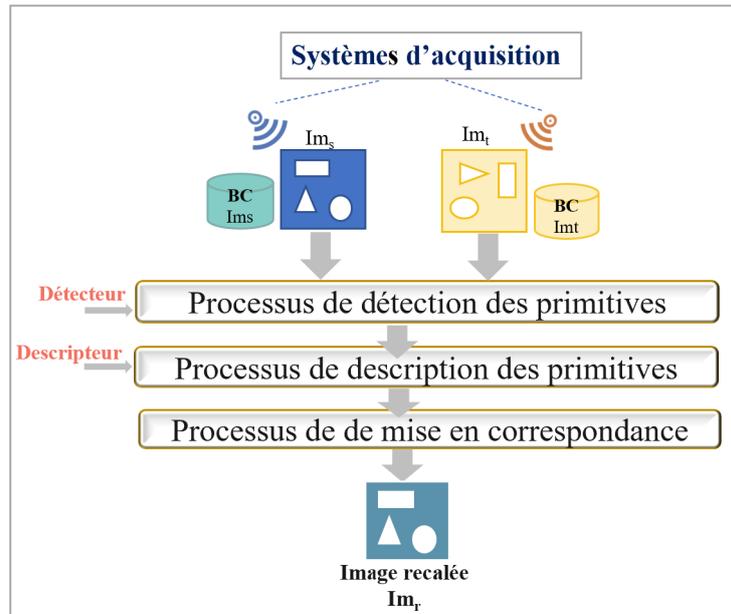


FIGURE 5.1 – Processus de recalage géométrique : Méthode BRISK

### 5.3.1 Détection des primitives Scale-Space

Le but de la détection des caractéristiques est de trouver des points d'image qui peuvent être détectés de manière fiable dans des différentes images de la même scène.

La méthodologie de détection des points d'intérêt de BRISK est inspirée de *AGAST* (Adaptive and Generic Accelerated Segment Test).

Le FAST (Features from Accelerated Segment Test) est étendu au plan image et à l'échelle-espace.

Dans le cadre de l'algorithme BRISK, l'espace de pyramide d'échelle est composé de  $n$  octaves  $c_i$  et  $n$  intra-octaves  $d_i$ , où  $i = 0, 1, \dots, n-1$  } et généralement  $n = 4$ .

Les octaves sont formées par des demi-échantillonnage progressif de l'image d'origine (correspondant à  $C_0$ ). Chaque intra-octave  $d_i$  est située entre les couches  $c_i$  et  $c_{i+1}$  (comme illustré sur la figure 5.2).

### 5.3.2 Description des primitives

La description des primitives a un impact significatif sur l'efficacité ultérieure de la correspondance des descripteurs, influençant également l'ensemble des performances de la méthode. Le descripteur BRISK est décrit par la chaîne binaire, proposée par *Michael Calondor* et mise en correspondance par *Hamming Distance*. En d'autres termes, la *distance de Hamming* peut être calculée très efficacement avec une opération *XOR* au niveau du bit.

Le descripteur BRISK adopte un modèle d'échantillonnage de voisinage fixe pour décrire les points caractéristiques. Quatre cercles concentriques sont construits à l'intérieur du bloc dont la taille est de  $40 \times 40$  pixels centrés sur le point d'intérêt, et des  $N$  ( $N = 60$ ) points avec une distribution uniforme et le même espacement sont respectivement obtenus sur les quatre cercles concentriques. Comme le montre la figure 5.3, les petits cercles bleus indiquent les emplacements

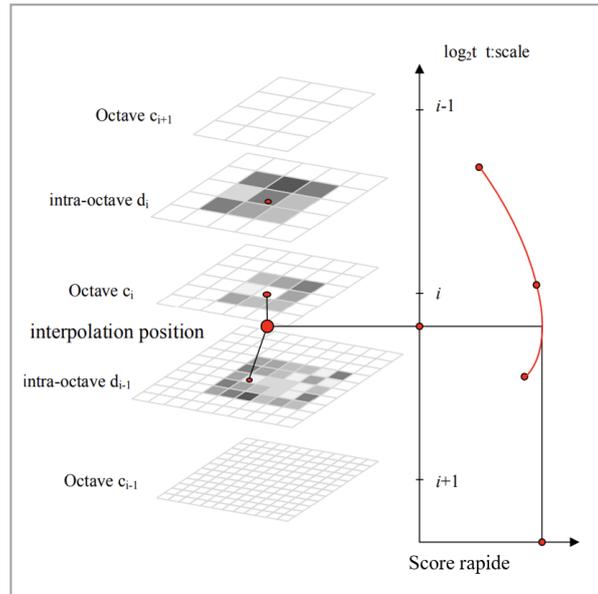


FIGURE 5.2 – Détection des points d'intérêt de l'espace d'échelle [Liu *et al.*, 2018]

d'échantillonnage. Afin d'éviter les effets d'alias lors de l'échantillonnage de l'intensité d'image d'un point  $\pi$  dans le motif, un lissage gaussien avec un écart type  $\sigma_i$  proportionnel à la distance entre les points sur le cercle respectif est appliqué.

La figure 5.3 présente un exemple de description des points d'intérêt de la méthode BRISK.

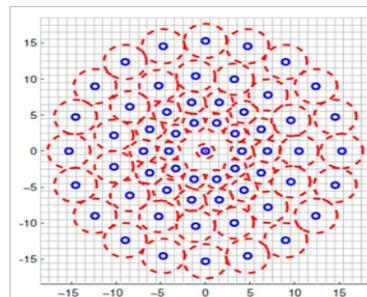


FIGURE 5.3 – Description de points d'intérêt dans l'espace d'échelle [Liu *et al.*, 2018]

### 5.3.3 Phase de mise en correspondance des primitives

L'appariement des primitives est réalisé en comparant les similitudes entre les descripteurs des deux points caractéristiques des deux images (source et cible). Puisque la méthode BRISK utilise la chaîne de bits binaire composée de 1 et 0 pour décrire les primitives extraites, la similitude des descripteurs est décrite en calculant la distance de Hamming du descripteur. Le calcul de la distance de Hamming est implémenté en utilisant une opération *XOR* au niveau du bit, c'est-à-dire deux valeurs participant à l'opération. Si leurs bits correspondants sont identiques, le résultat est «0», sinon c'est «1». Ensuite, les statistiques de «1» sont comptées et plus le nombre de «1» est élevé, plus les deux descripteurs sont dissemblables, sinon le contraire.

## 5.3.4 Avantages et limites de la méthode BRISK

TABLEAU 5.1 – Avantages et limites de la méthode BRISK [Marzouka *et al.*, 2020a]

Methodes	Avantages	Limites
<b>BRISK</b>	<ul style="list-style-type: none"> <li>- Performante pour les calcul en temps réel et puissance de calcul limitée</li> <li>- Invariante à la rotation, changement d'échelle et l'ajout du bruit</li> <li>- Complexité temporelle modérée : temps de calcul faible</li> </ul>	<ul style="list-style-type: none"> <li>- Nombre de faux amers élevé</li> <li>- Sensible au bruit</li> </ul>

Comme mentionné précédemment, la méthode BRISK souffre du nombre important de faux amers. Cela a une influence négative sur la qualité de recalage.

Dans cette section, nous allons effectuer une étude comparative des résultats d'expérimentations de BRISK au niveau pixelique (méthode existante) avec BRISK dans le nouvel espace de représentation des connaissances proposée (niveau sémantique) :  $BRISK_{GL}$  vs  $BRISK_{\pi}$ .

La méthode  $BRISK_{\pi}$  proposée vise à surmonter les limites de la méthode BRISK existante tels que l'augmentation de la fiabilité de l'algorithme de recalage afin d'éliminer les éventuels faux amers et d'obtenir une meilleure qualité de recalage plus efficace. Notre méthode BRISK possibiliste ( $BRISK_{\pi}$ ) proposée est nommée *textbfPBRISK* et comprend une phase de projection basée sur la théorie des possibilités qui permet d'obtenir un ensemble de cartes de possibilités projetées à partir de l'image (image source).

L'idée principale de l'approche proposée consiste à extraire des connaissances sémantiques liées au contenu de l'image source en utilisant la théorie des possibilités. En fait, si la scène considérée comprend  $\sim M$  cartes (pour lesquelles nous supposons la connaissance de leurs distributions de possibilités associées), alors, le processus de projection de connaissances sémantiques transforme chaque image en  $\sim M$  cartes possibilites, où chaque carte est formée par une données de possibilité de la carte donnée (un seule contexte). Ce processus de transformation des connaissances est d'une manière ou d'une autre, supposé imiter le processus de focalisation de l'attention visuelle de l'expert.

Un avantage majeur de l'approche de projection des connaissances proposée consiste à minimiser le risque de conflit, au cours du processus d'appariement, entre les caractéristiques extraites des images source et cible.

L'approche proposée consiste donc à appliquer les phases de la méthode  $BRISK$  sur l'ensemble des cartes possibilistes et non sur l'image d'origine, où chaque carte a un contexte unique.

### 5.3.5 Phase d'expérimentation

Dans cette section, nous décrivons notre approche, qui consiste à améliorer la qualité de la détection ainsi que l'appariement pour augmenter les performances de la méthode.

Pour les expérimentations, l'algorithme d'approche proposé est appliqué sur une base d'images médicale.

La figure 5.4 illustre une coupe du cerveau acquise par imagerie IRM "Magnetic Resonance Imaging" (image IRM d'un patient prise à **Hopital de Brest** : <http://www.Pacs.diamorphos.com>).

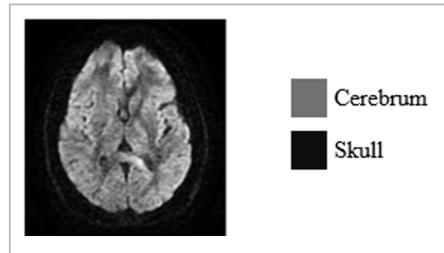


FIGURE 5.4 – Exemple d'une image IRM d'un cerveau d'un patient

### 5.3.6 Résultats d'expérimentation

Nous commençons par la présentation de la vérité terrain. En fait, nous évaluons la performance de la méthode BRISK en utilisant les critères d'évaluation suivants : calcul du nombre de faux amers, calcul du temps d'exécution et le calcul de l'erreur de précision.

Le tableau 5.2 présente l'ensemble des résultats obtenus sur un ensemble d'images en appliquant la fonction de transformation de type rotation avec un angle de rotation qui est égal à 30°.

TABLEAU 5.2 – Résultats d'expérimentation

Vérité terrain :	
Fonction de transformation : <b>Rotation 30°</b>	
<b>Nombre de faux amers</b>	54%
<b>Temps de calcul</b>	3.25 s
<b>Erreur de précision</b>	7,2 pixel

Le résultat le plus important de cette expérimentation est que le nombre de faux amers est très important. De ce fait, le résultat de précision n'est pas assez efficace.

Nous évaluons dans ce qui suit l'effet de la phase de projection possibiliste proposée sur la qualité de recalage de la méthode BRISK existante.

Dans cette étude, les transformations de rotation, de translation et d'ajout de bruit sont considérées à travers les expériences menées. Pour chaque type de transformation utilisé, plusieurs paramètres de transformation sont utilisés :

- Rotation :  $\theta_1, \theta_2, \theta_3, \dots, \theta_N$  (i.e., N angles de rotation) ;
- Translation :  $(\Delta_{x1}, \Delta_{y1}), (\Delta_{x2}, \Delta_{y2}), (\Delta_{x3}, \Delta_{y3}), \dots, (\Delta_{xK}, \Delta_{yK})$  (i.e., K valeurs de translation) ;
- Bruit gaussien :  $N(0, \sigma_1), N(0, \sigma_2), N(0, \sigma_3), \dots, N(0, \sigma_L)$  (i.e., L images de bruit normal avec différentes valeurs d'écart type).

La première expérience consiste à appliquer la phase de projection possibiliste sur deux images, la première est une image source ( $Image_s$ ) et la seconde est l'image obtenue après une transformation géométrique, ( $Image_t$ ) . Nous présentons un exemple de fonction de transformation de rotation (Figure 5.5).

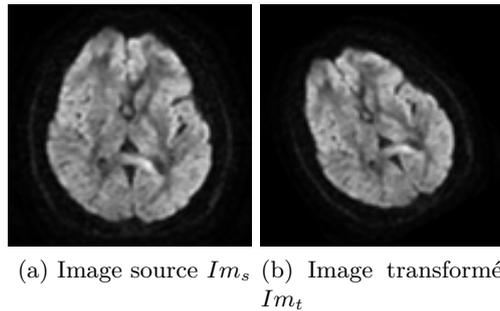
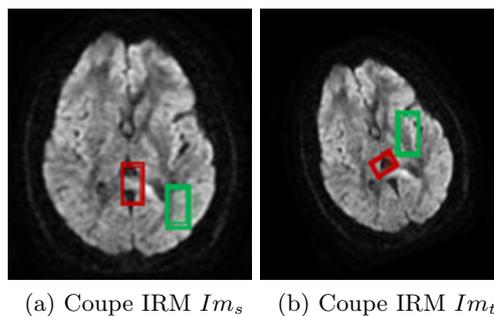


FIGURE 5.5 – Image source du cerveau, (a), et l'image transformée de l'image source, (b), FT : Rotation

L'application de la projection possibiliste, utilisant les connaissances basées à la fois sur les images source et cible, permet d'identifier deux classes sémantiques représentées par l'ensemble  $\Omega_{sem} = \{C_1, C_2\}$ . Une analyse approfondie de ces classes sémantiques, des deux images, montre que C1 représente la classe du cerveau et C2 la classe du crâne. Les estimations de cartes possibilistes sont basées sur une méthode indirecte guidée par des connaissances d'experts (c.-à-d. Classification supervisée).

Rappelons que la théorie des possibilités se concentre sur la gestion de l'incertitude épistémique : c'est-à-dire l'incertitude dans un contexte où les connaissances disponibles sont exprimées de manière ambiguë.

La figure 5.5 montre un exemple des distributions de possibilité estimées pour les deux classes sémantiques de l'image considérée.



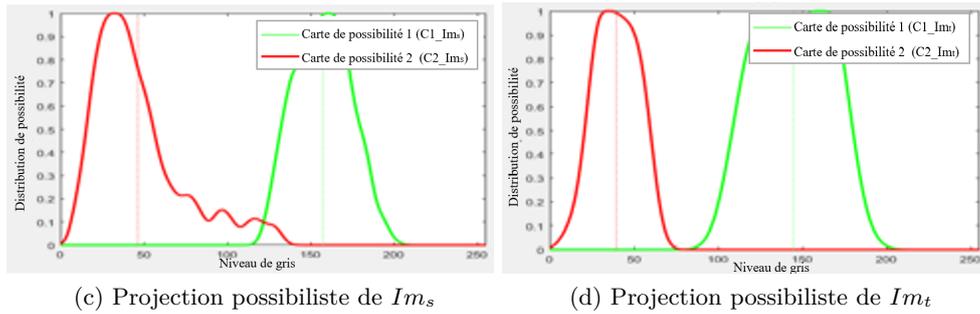


FIGURE 5.5 – Estimation des distributions de possibilités résultant des domaines d'apprentissage des experts (a) Image source,  $Image_s$ , (b) Image cible,  $Image_t$ , (c) Distribution de possibilité  $Image_s$ , (d) Distribution de possibilité de  $Image_t$

Dans cette section, des résultats de comparaison expérimentale utilisant différents types de transformations de la méthode BRISK appliquée sur des images avec deux bases de connaissances ; au niveaux de gris, appelées GL, et au niveau semi-sémantique possibiliste, appelé  $\pi$ , sont donnés.

Les résultats de l'application de la méthode BRISK ainsi que l'approche PBRISK proposée sont détaillés dans la sous-section suivante. Trois facteurs d'évaluation sont pris en compte : le temps de traitement, le nombre de et l'erreur de précision.

La figure 5.6 présente les résultats de l'évaluation du temps de traitement des résultats du BRISK par rapport à l'approche proposée PBRISK.

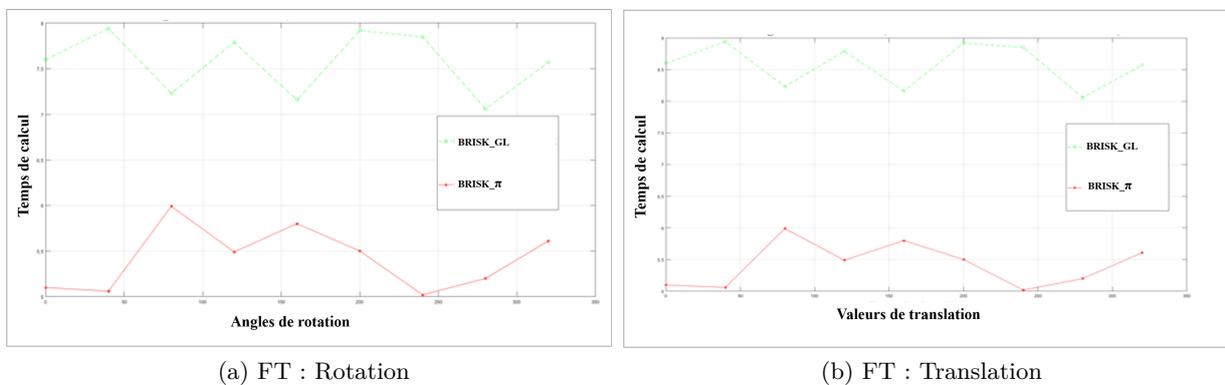


FIGURE 5.6 – Évaluation du temps de traitement des résultats du BRISK par rapport à l'approche proposée (Image du cerveau)

Les résultats de comparaison des méthodes BRISK et PBRISK sont présentés dans le tableau suivant 5.3.

### 5.3.7 Interprétation, comparaison et évaluation

Les résultats présentés révèlent que la méthode PBRISK offre de nombreux avantages par rapport à la méthode BRISK existante. En effet, nous pouvons bien remarquer une réduction importante au niveau du nombre de faux amers par l'approche proposée.

Le point clé de l'approche proposée est l'amélioration de la précision.

TABLEAU 5.3 – Tableau comparatif des résultats d'évaluation de BRISK et PBRISK

Fonction de transformation : <b>Rotation 30°</b>			
Méthode	Nombre de faux amers	Temps de calcul	Erreur précision
<b>BRISK</b>	54%	3.25 s	7.2 pixel
<b>PBRISK</b>	5%	3.02 s	0.84 pixel

Les projections impliquées dans le processus du recalage proposée ont permis un appariement rigoureux du fait que les points d'intérêt des couples d'images à apparier appartienne à des classes sémantiques homogènes. Ceci correspond au choix initial de l'approche du recalage qui vise à opérer avec des cartes issues de projections sémantiques identiques.

Dans cette partie de notre travail, nous avons présenté l'apport de la projection des connaissances au niveau sémantique sur la performance de la méthode BRISK. La méthode BRISK présente de nombreux avantages mais elle souffre du nombre élevé de faux amers. C'est pourquoi nous proposons l'approche PBRISK pour améliorer le recalage en utilisant la théorie des possibilité pour un meilleur recalage.

Le résultat le plus important de l'expérimentation *PBRISK* est que le nombre de faux amers est considérablement réduit, et ce, pour toutes les expérimentation des différents patients pour une transformation de type rotation sont améliorés. De plus, comme nous pouvons le constater, le temps de traitement est clairement réduit lorsque ces algorithmes sont appliqués en utilisant le niveau de connaissance possibiliste semi-sémantique proposé au lieu de l'espace de représentation des connaissances en niveaux de gris. En d'autres termes, outre le fait que la projection des connaissances et la fusion possible des recalages géométrique nécessitent un temps de traitement supplémentaire, la réduction considérable du nombre de faux amers garantit la réduction globale du temps d'exécution.

L'approche proposée qui consiste à projeter la base de connaissances au niveau pixelique de la méthode BRISK dans un espace de représentation des connaissances sémantique avec le type de transformation "Rotation" a permis l'amélioration de la performance de la méthode BRISK, ce qui nous encourage à appliquer notre approche dans d'autres contextes.

Nous proposons dans ce qui suit à évaluer l'apport de notre approche pour d'autres méthodes de recalage existantes (SURF, ORB, BRIEF) et avec d'autres types de transformation. Ainsi, nous proposons, de réaliser les expériences sur un autre type d'images de même modalité (Images satellites 2D)

#### 5.4 Application sur des images satellites : Contexte supervisé

Dans cette section, des évaluations qualitatives et quantitatives de l'approche de recalage supervisé possibiliste proposé sont présentées. Pour les expérimentations, nous appliquons notre approche sur des images de télédétection. La figure 5.7 montre une image *Quickbird* haute

résolution de la base d'images Landsat «**Razazah Lake**» acquise en juin 2006, et située à Ain Draham Tunisie (CNCT). A partir de cette image, (Bande spectrale), nous avons créé une base d'images composée de 100 images (de taille 250 \* 250 chacune). Toutes les images de la base contiennent un nombre fini de cartes. Certaines de ces images sont illustrées dans la figure 5.8.

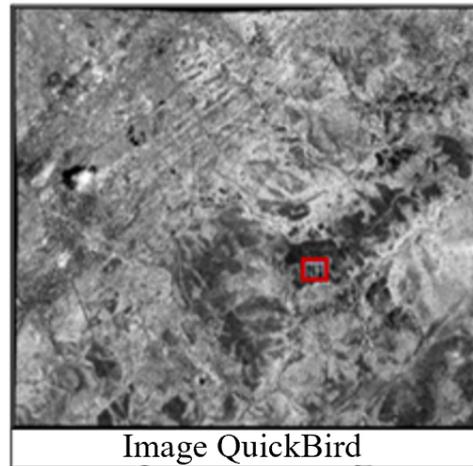


FIGURE 5.7 – Images de l'étude expérimentale

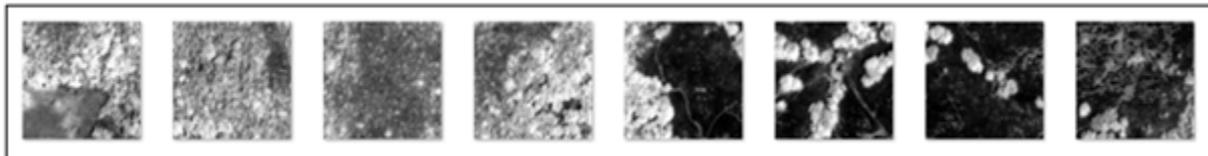


FIGURE 5.8 – Exemples d'images de la base d'images Quick Bird construite

#### 5.4.1 Présentation des résultats

L'étude expérimentale des résultats de l'approche du recalage possibiliste est principalement basée sur l'application d'un protocole d'évaluation, figure 5.9, afin de générer des images cibles (dites aussi transformées) correspondant à des différents types de transformations appliquées à des images sources d'entrées. Par conséquent, l'entrée de ce protocole est une image source et la sortie est une image cible.

Dans cette étude, les transformations de rotation, de translation et d'ajout de bruit sont considérées à travers les expériences menées. Pour chaque type de transformation utilisé, plusieurs paramètres de transformation sont utilisés :

- **Rotation** :  $\theta_1, \theta_2, \theta_3, \dots, \theta_N$  (i.e., N angles de rotation) ;
- **Translation** :  $(\Delta_{x1}, \Delta_{y1}), (\Delta_{x2}, \Delta_{y2}), (\Delta_{x3}, \Delta_{y3}), \dots, (\Delta_{xK}, \Delta_{yK})$  (i.e., K valeurs de translation) ;
- **Bruit gaussien** :  $N(0, \sigma_1), N(0, \sigma_2), N(0, \sigma_3), \dots, N(0, \sigma_L)$  (i.e., L images de bruit normal avec différentes valeurs d'écart type).

Un exemple de ce schéma d'expérimentation est donné dans la figure 5.10.

Dans cet exemple, une géométrie de type rotation est appliquée à l'aide d'une image *Landsat* de

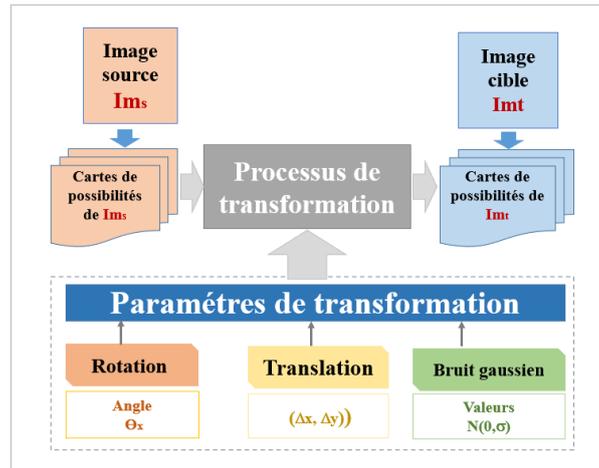
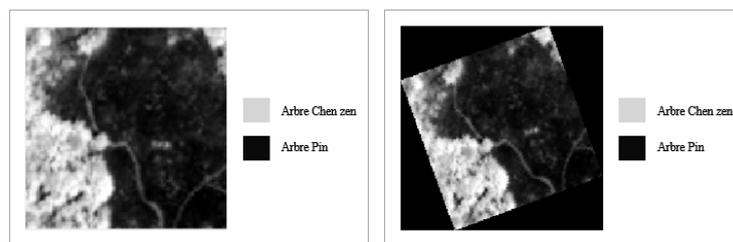


FIGURE 5.9 – Protocole d'expérimentation

la base de données “**Razazah Lake**”, la première nommée ( $Im_s$ ) (qui est l'image source) et la seconde est l'image obtenue après une transformation géométrique, ( $Im_t$ ).



(a) Image source Quickbird image (b) Image cible Quickbird image

FIGURE 5.10 – Applications de transformation

Comme mentionné précédemment, l'approche de recalage possibiliste proposée comporte trois phases principales : la projection des connaissances à l'aide d'une base de connaissance et en fonction des classes thématiques données par l'expert, le recalage possibiliste supervisée de l'ensemble des cartes de possibilités et finalement la phase de fusion de l'ensemble des recalages partiels donnés par la deuxième phase de notre approche afin d'obtenir le recalage cherché.

L'application de la projection possibiliste, utilisant les connaissances basées à la fois sur les images source et cible, permet d'identifier deux ensembles de classes sémantiques représentées par l'ensemble  $\Omega_{sem} = \{map_1, map_2\}$ .

Une analyse approfondie de ces cartes sémantiques, des deux images, montre que  $map_1$  représente la carte *Arbre Chen zen* et  $map_2$  représente la carte *Arbre Pin map*.

Les estimations de cartes possibilistes sont basées sur une méthode indirecte guidée par les connaissances de l'expert : Classification supervisée. En effet, la phase de projection repose sur la sélection de plusieurs domaines d'apprentissage. Les pixels de ces zones d'apprentissage sont ensuite utilisés afin d'estimer les distributions de possibilités pour différentes classes sémantiques.

Une question importante, pour l'application de cette théorie, concerne l'évaluation des différentes distributions de possibilités. En fait, la modélisation des connaissances permet d'utiliser

des formes trapézoïdales et standard de fonctions d'appartenance floue (transformées selon leurs sens sémantique en distributions de possibilités.

Dans cette étude, nous avons appliqué une méthode basée sur l'estimation des fonctions de densité de probabilité, *pdf*, (à partir d'un petit ensemble de domaines d'apprentissage indiqués par l'expert), et les *pdf* «mal définis» sont transformés en des distributions de possibilités.

La figure 5.11 montre un exemple des distributions de possibilité estimés pour les deux cartes sémantiques des deux images considérées (images source et cible).

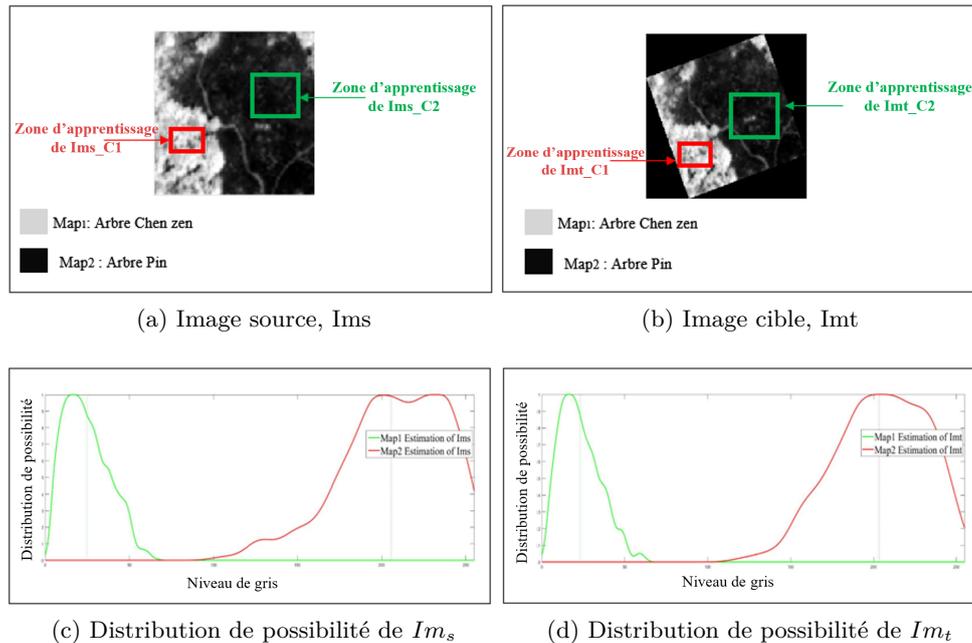


FIGURE 5.11 – Distributions de possibilités estimées résultant des domaines d'apprentissage

De plus, les cartes possibilistes résultantes des deux images source et cible sont illustrées dans la figure 5.12.

L'étape suivante du processus du recalage géométrique possibiliste consiste à réajuster les primitives issues de différentes cartes de possibilités par l'application des phases du recalage géométrique en faisant varier la valeur du paramètre de la fonction de transformation.

Les résultats de l'application des méthodes de recalage géométrique existantes ainsi que les résultats l'approche de recalage possibiliste proposée, utilisant les différentes transformations sont détaillés dans la sous-section suivante. Trois facteurs d'évaluation majeurs sont considérés : le temps de calcul, le nombre de faux amers et la précision. La valeur moyenne de chaque facteur est calculée en fonction des résultats obtenus pour chaque image de la base d'images *Quick bird*.

#### 5.4.1.1 Résultats d'expérimentations : Une seule transformation

Dans cette section, nous présentons les résultats de la comparaison expérimentale du recalage classique (utilisant une base de connaissances au niveau de gris) et du recalage possibiliste (base de connaissance semi-sémantique).

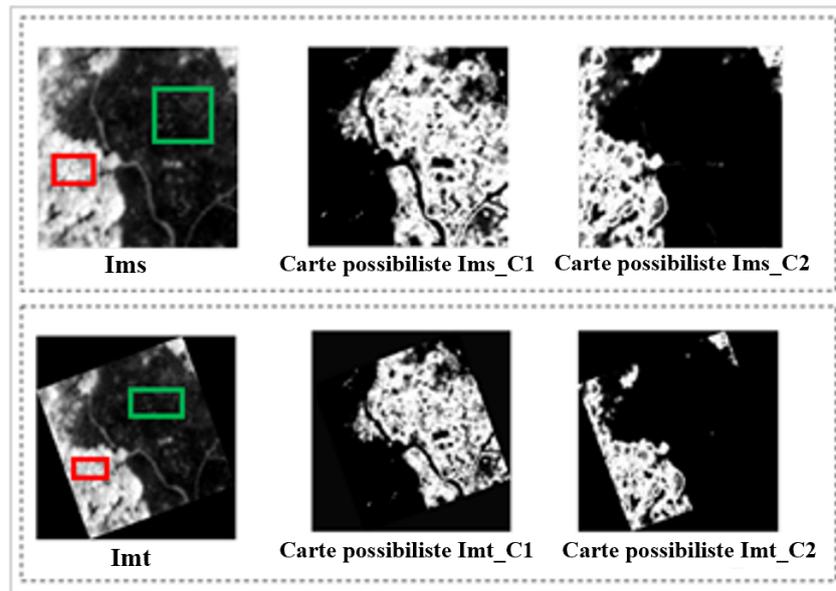


FIGURE 5.12 – Cartes possibilistes résultantes des images source et cible

Nous considérons quatre méthodes de recalage qui sont respectivement SURF, BRISK, BRIEF et ORB où nous comparons les résultats de recalage obtenus selon la base en connaissances ( $BC$ ) utilisée :  $BC$  au niveau pixelique nommée ( $GL$ ) *vs*  $BC$  au niveau sémantique appelée ( $\pi$ ).

La première expérimentation consiste en l'application d'une seule transformation : rotation, translation ou addition du bruit gaussien.

Nous prenons un exemple de transformation, la rotation est qui est appliquée pour «simuler» des images cibles. Des différents angles de transformation de rotation sont considérés dans l'intervalle  $[0^\circ - 320^\circ]$  avec un pas de rotation de  $40^\circ$ .

Le tableau 5.4 présente les résultats de la comparaison en termes de temps de calcul (T.C) et de nombre de faux amers (F.A) dite en anglais "*outliers*" entre les méthodes de recalage SURF, ORB, BRISK et BRIEF appliquées dans des espaces de représentation des connaissances pixeliques  $GL$  existantes et des méthodes de recalage appliquées dans des espaces de représentation des connaissances sémantiques proposées  $\pi$ .

TABLEAU 5.4 – Résultats de la comparaison des performances en utilisant algorithmes SURF, BRIEF, BRISK et ORB, niveaux de représentation des connaissances  $GL$  *vs*  $\pi$ 

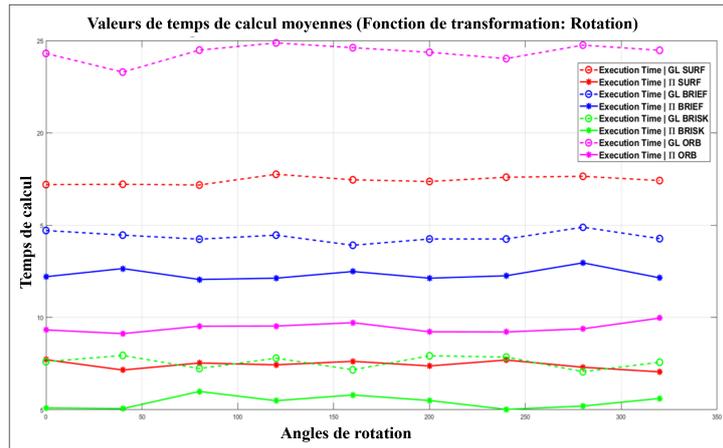
Angle de rotation		$0^\circ$	$40^\circ$	$80^\circ$	$120^\circ$	$160^\circ$	$200^\circ$	$240^\circ$	$280^\circ$	$320^\circ$
SURF_T.C(s)	GL	15.2	15.22	15.18	14.76	14.86	15.37	15.60	15.65	15.42
	$\pi$	06.71	06.15	06.53	06.43	06.62	06.37	06.69	06.30	06.05
SURF_F.A(%)	GL	58.3	54.2	32.1	29.5	33.3	21.8	14.6	26.8	39.2
	$\pi$	19.3	20.2	21.1	15.2	19.3	10.3	9.6	20.1	21.2

<b>SURF_précision</b>	GL	0.031	0.032	0.032	0.034	0.033	0.038	0.036	0.039	0.038
	$\pi$	0.81	0.79	0.82	0.83	0.80	0.81	0.83	0.86	0.87
<b>ORB_T.C(s)</b>	GL	24.30	23.29	23.48	26.87	24.61	32.36	35.02	31.75	29.47
	$\pi$	09.32	08.12	08.52	09.53	09.71	08.22	09.21	08.38	09.96
<b>ORB_F.A(%)</b>	GL	43.2	44.8	63.2	41.9	23.8	11.3	16.5	26.7	33.3
	$\pi$	2.1	1.9	2.3	2.2	0	0	1.1	0	1.6
<b>ORB_précision</b>	GL	0.049	0.040	0.043	0.043	0.044	0.045	0.048	0.049	0.048
	$\pi$	0.62	0.62	0.64	0.66	0.63	0.63	0.69	0.67	0.65
<b>BRISK_T.C(s)</b>	GL	7.60	7.94	8.23	8.79	8.16	10.92	8.85	9.06	8.57
	$\pi$	6.1	7.06	7.99	6.49	6.80	6.50	8.02	8.20	7.61
<b>BRISK_F.A(%)</b>	GL	73.0	73.2	70.5	79.2	71.2	77.3	86.2	80.6	81.3
	$\pi$	20.0	20.3	19.5	23.4	15.2	15.6	18.4	17.17	19.5
<b>BRISK_précision</b>	GL	0.039	0.040	0.043	0.041	0.046	0.043	0.046	0.047	0.043
	$\pi$	0.63	0.62	0.61	0.67	0.65	0.61	0.69	0.68	0.67
<b>BRIEF_T.C(s)</b>	GL	14.70	16.45	14.23	14.45	13.90	14.24	14.24	14.88	15.26
	$\pi$	13.20	15.64	14.05	14.12	12.48	13.12	12.25	13.95	15.14
<b>BRIEF_F.A(%)</b>	GL	51	45	22	36	40	42	51	53	57
	$\pi$	5.2	6.5	6.2	7.33	10.11	8.3	9.3	9.8	8.9
<b>BRIEF_précision</b>	GL	0.051	0.051	0.053	0.051	0.054	0.054	0.057	0.057	0.058
	$\pi$	0.94	0.93	0.93	0.92	0.94	0.97	0.96	0.96	0.98

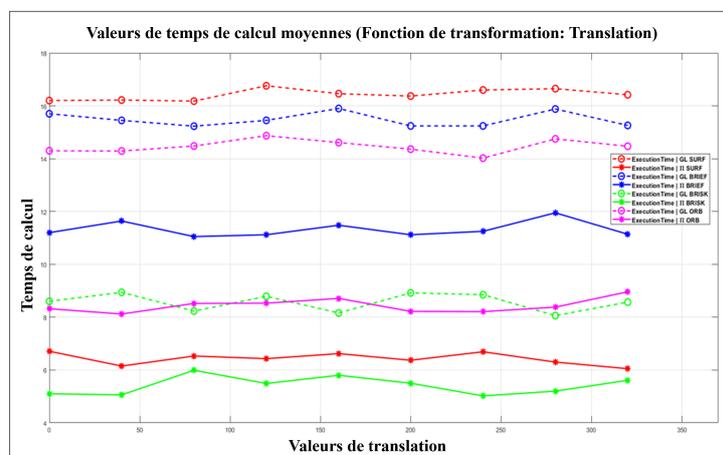
Nous dégageons à travers cette expérimentation un résultat important qui concerne le nombre de faux amers considérablement réduit, et ce, pour toutes les valeurs d'angles de rotation et pour les quatre méthodes de recalage évaluées. De plus, comme nous pouvons le constater, le temps de traitement de toutes les méthodes de recalage est clairement réduit lorsque nous appliquons le recalage dans le niveau des connaissances possibiliste semi-sémantique proposé au lieu de l'espace de représentation des connaissances au niveau de gris.

En d'autres termes, outre le fait que la projection des connaissances et la fusion des recalages partiels de l'ensemble des cartes possibilistes nécessitent un temps de traitement supplémentaire, la réduction considérable du nombre de faux amers garantit la réduction globale du temps d'exécution. Un avantage majeur important de l'approche proposée est qu'elle améliore la précision de recalage (comme le montrent le tableau 5.4).

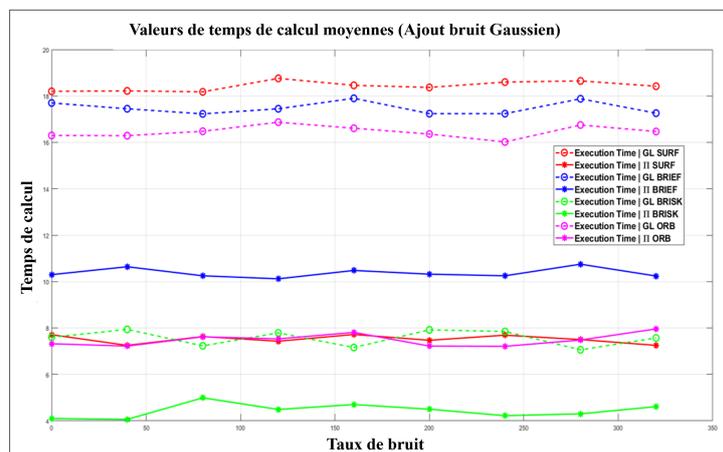
Des résultats similaires sont obtenus lorsque cette approche est appliquée en utilisant la translation et l'ajout de bruit gaussien. Ces résultats concernant le temps de traitement sont repris dans la figure 5.13.



(a) Fonction de transformation : Rotation



(b) Fonction de transformation : Translation



(c) Bruit gaussien

FIGURE 5.13 – Résultats de comparaisons du temps de calcul des méthodes au niveaux GL *vs*  $\pi$  ; méthodes : ORB,BRISK,SURF et BRIEF ; Base d’images QuickBird

Dans ce qui suit, nous présentons les résultats d’expérimentations du calcul du nombre de faux amers (%) pour chacune des méthodes de recalage ORB, SURF, BRIEF et BRISK en comparant le nombre détecté dans l’espace de représentation de connaissances considéré ; *GL* (le niveau pixelique : Approche existante) *vs*  $\pi$  (le niveau sémantique : Approche possibiliste

proposée).

Les figures 5.14, 5.15, 5.17 et 5.16 illustrent les courbes représentant le nombre de faux amers (%) pour chacune des comparaisons selon les transformations Rotation, Translation et ajout du bruit gaussien. En fait, ■ présente les résultats de l'approche supervisée possibiliste proposée (recalage dans un espace de représentation sémantique), et ■ présente les résultats des méthodes existantes (recalage dans un espace de représentation pixelique).

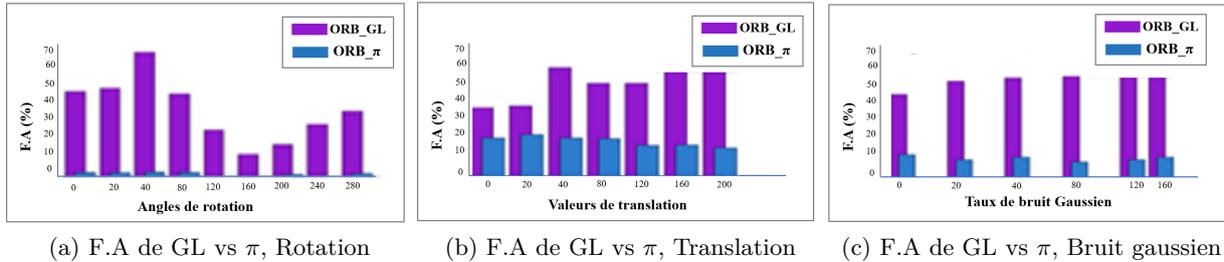


FIGURE 5.14 – Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs  $\pi$ , méthode ORB

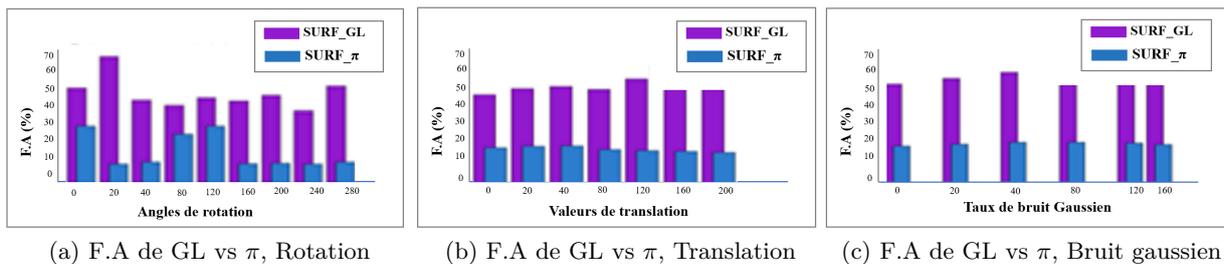


FIGURE 5.15 – Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs  $\pi$ , méthode SURF

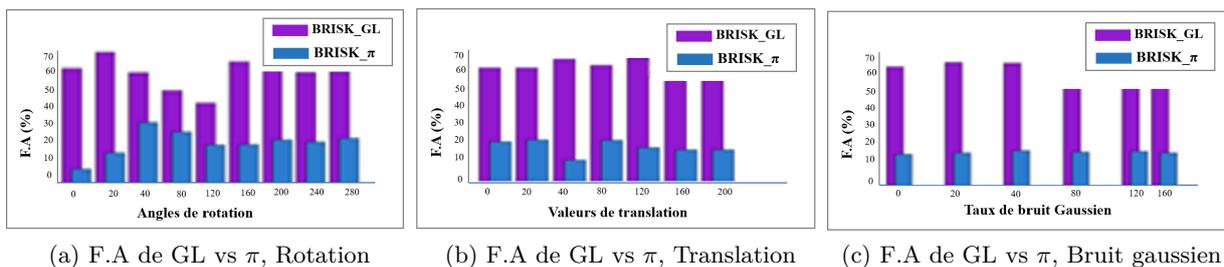


FIGURE 5.16 – Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs  $\pi$ , méthode BRISK

Les figures 5.14, 5.15, 5.16 ainsi que 5.17 montrent un écart important entre le nombre de faux amers (%) détectés dans les deux espaces de représentation des connaissances (GL vs  $\pi$ ) en faisant varier la méthode de détection et de description des primitives, respectivement ORB, SURF, BRISK et BRIEF. Nous pouvons bien remarqué que notre approche de recalage possibiliste proposée permet de réduire le nombre de faux amers (%). Cette réduction a un impacte très important sur le résultat de recalage géométrique.

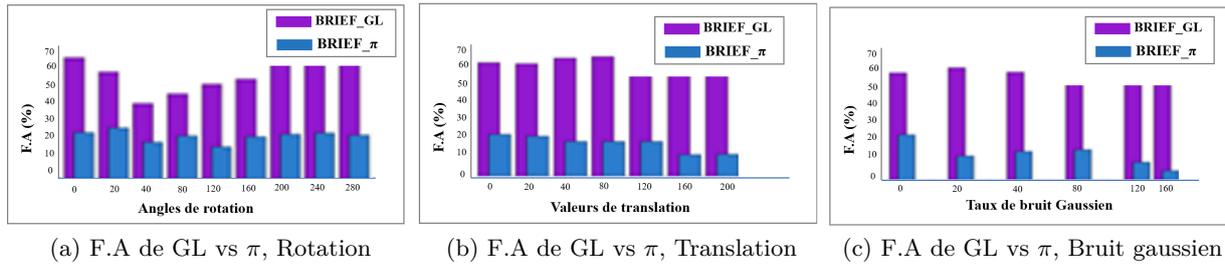


FIGURE 5.17 – Évaluation du nombre de faux amers (F.A %) des méthodes de recalage selon l'espace de représentation des connaissances GL vs  $\pi$ , méthode BRIEF

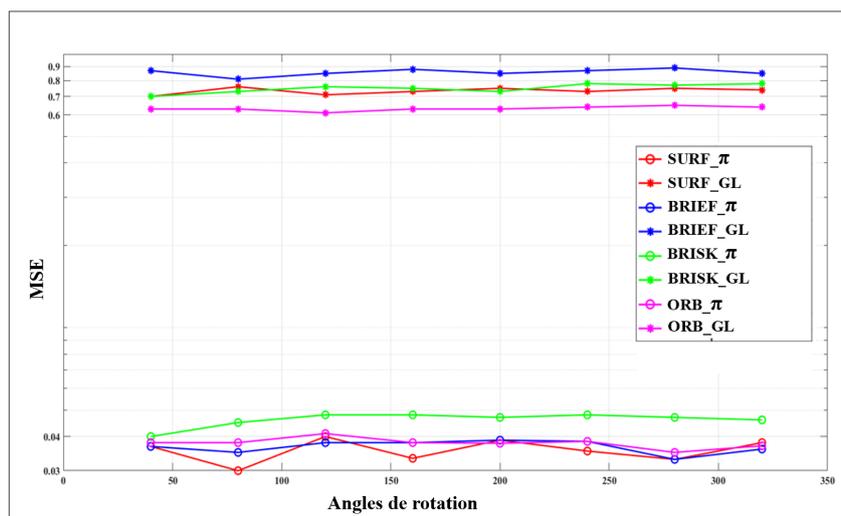
Ainsi, notre approche de recalage possibiliste proposée est fiable pour des divers types de fonctions de transformations géométrique ; comme il le montre les courbes d'évaluations. L'approche de recalage possibiliste permet de réduire le nombre de faux amers pour les fonctions de transformation de types : rotation 5.14a, 5.15a, 5.16a et 5.17a ; translation 5.14b, 5.15b, 5.16b et 5.17b et même elle est moins sensible aux bruits 5.14c, 5.15c, 5.16c et 5.17c pour les quatre méthodes d'évaluation ORB, SURF, BRISK et BRIEF.

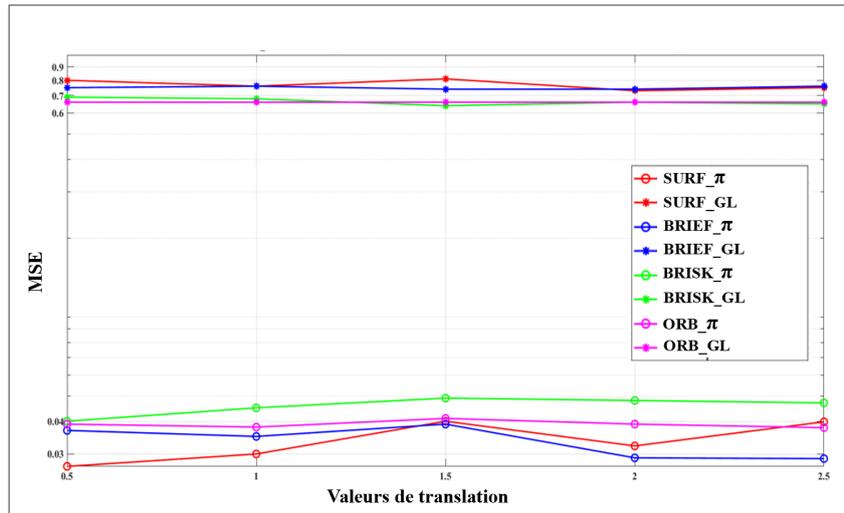
L'expérimentation suivante consiste à évaluer notre approche de recalage géométrique possibiliste proposée en terme d'erreur de précision.

C'est pour cela, nous calculons les valeurs de l'erreur de précision pour les trois types de fonctions : Rotation, translation et ajout du bruit gaussien.

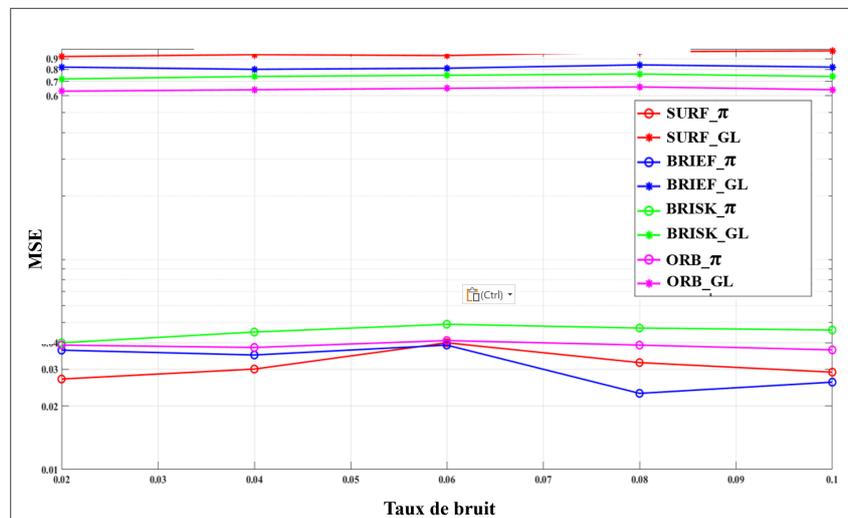
Nous comparons les résultats des méthodes SURF, BRIEF, BRISK et ORB selon leurs espaces de représentation des connaissances, GL : Niveau de représentation des connaissances existant et  $\pi$  : Niveau de représentation des connaissances proposé (Niveau semi-sémantique).

Les résultats de cette expérimentation sont présentés dans les courbes de la figure 5.17.





(b) Fonction de transformation : Translation



(c) Bruit gaussien

FIGURE 5.17 – Résultats de comparaisons des valeurs d'erreurs de précision des méthodes au niveaux GL *vs*  $\pi$ ; méthodes : ORB, BRISK, SURF et BRIEF

En effet, tous les résultats expérimentations présentés confirment l'apport de la phase de projection des connaissances au niveau sémantique proposée, cette dernière a permis de réduire le nombre de faux amers, de réduire le temps de calcul ainsi de réduire les valeurs de l'erreur de précision.

En conséquence, nous avons pu confirmer la fiabilité de notre approche de recalage possibiliste proposée.

Cette dernière est basée sur des connaissances au niveau sémantique utilisant la théorie des possibilités pour la projection des connaissances.

Nous proposons dans ce qui suit d'évaluer notre approche de recalage géométrique possibiliste en combinant plusieurs types de transformations.

### 5.4.1.2 Résultats d'expérimentations : *Combinaison de transformations*

Dans cette section, les expérimentations précédentes sont reconduites en utilisant des transformations géométriques combinées (c'est-à-dire l'utilisation simultanée de plusieurs transformations géométriques). De même, pour les expérimentations de mono-transformation, des comparaisons de performances utilisant des différents types de transformations combinées des méthodes de recalage standard existantes (appliquées sur des images au niveau de gris) et le niveau semi-sémantique possibiliste sont menées. Les transformations de rotation et de translation combinées à un bruit de type additif sont évaluées en utilisant plusieurs paramètres de transformations combinées.

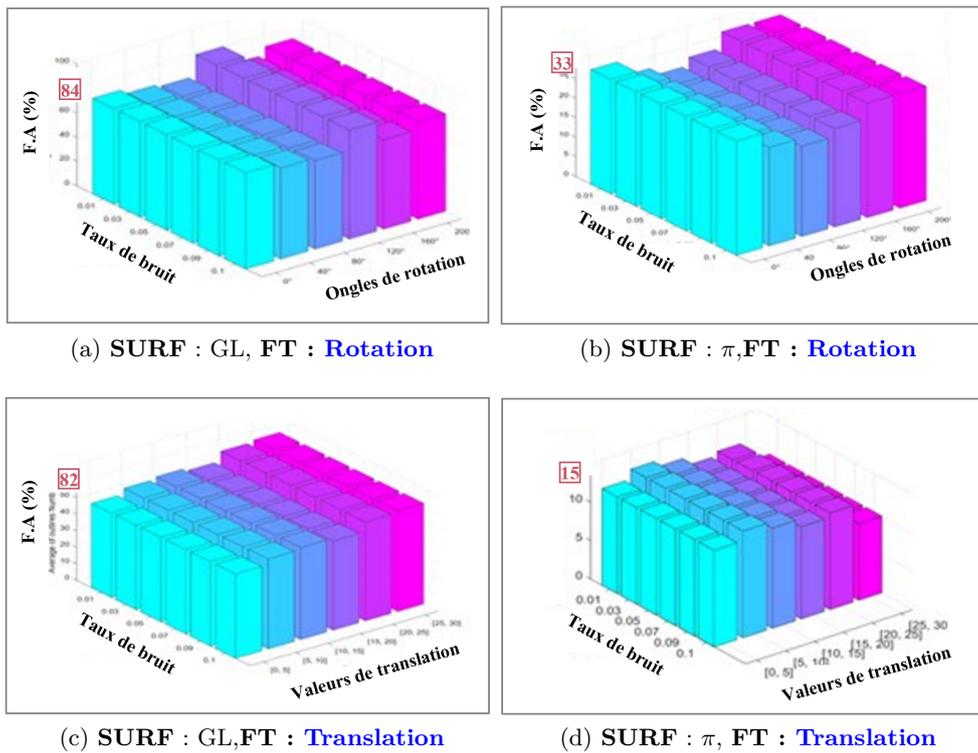
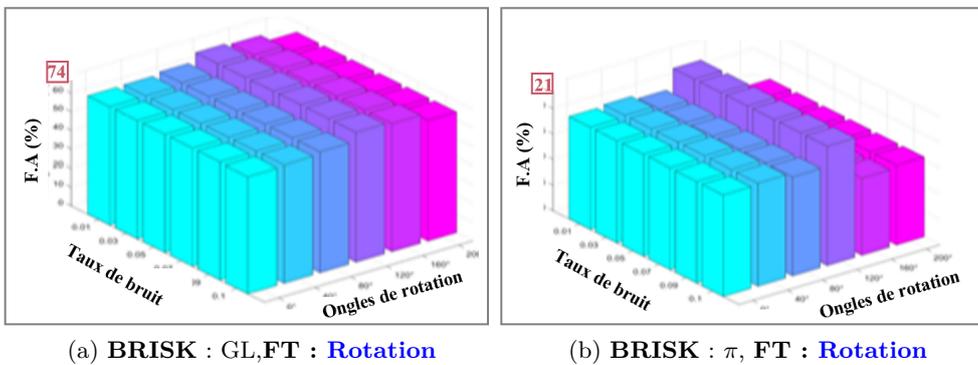


FIGURE 5.18 – Résultats de la comparaison du nombre de faux amers des méthodes  $SURF_{GL}$  vs  $SURF_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit



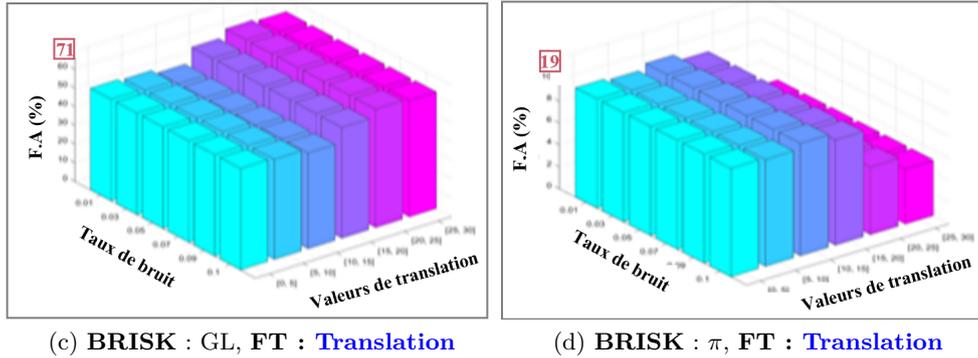


FIGURE 5.18 – Résultats de la comparaison du nombre de faux amers des méthodes  $BRISK_{GL}$  vs  $BRISK_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit

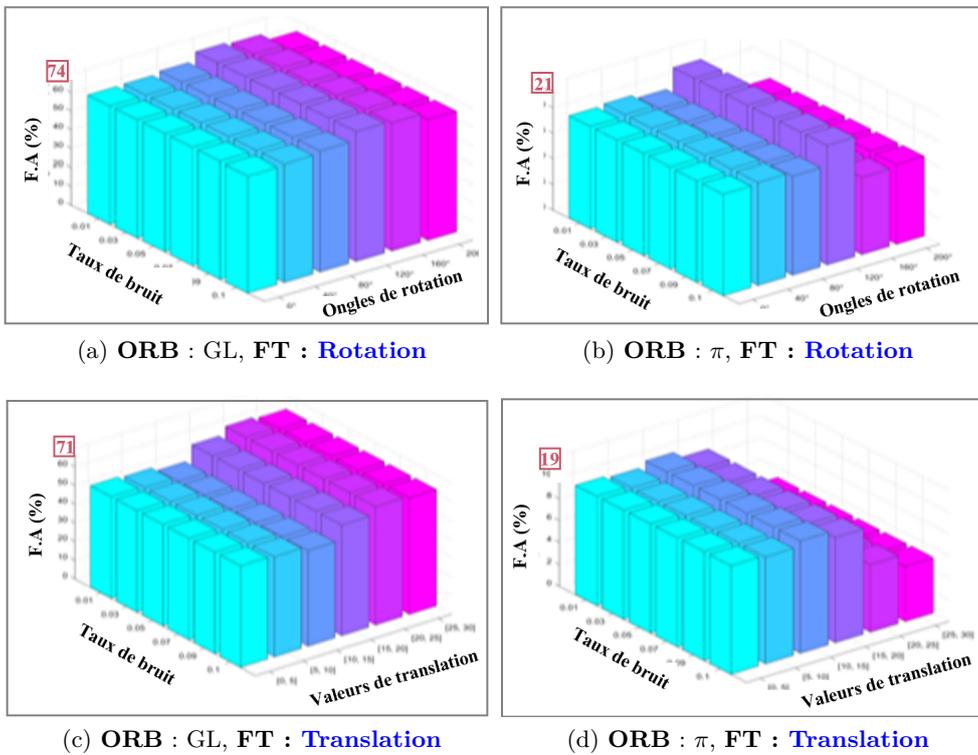


FIGURE 5.19 – Résultats de la comparaison du nombre de faux amers des méthodes  $ORB_{GL}$  vs  $ORB_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit

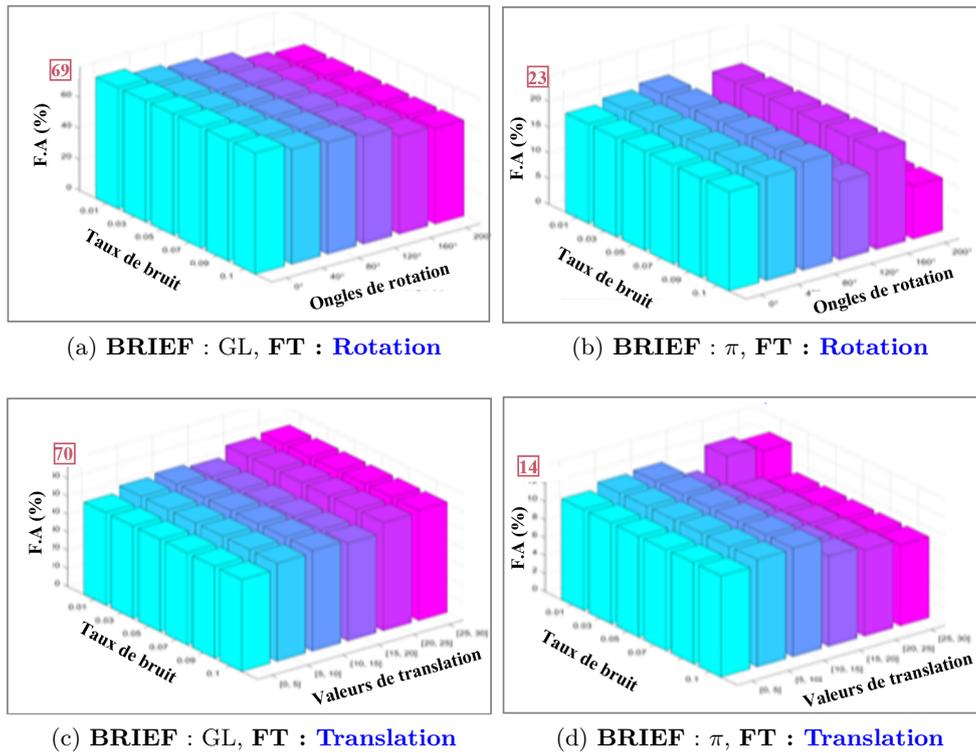
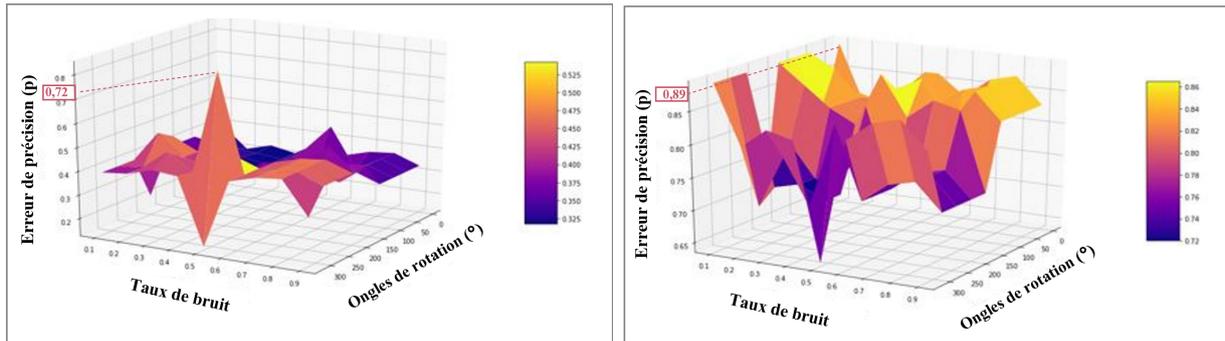


FIGURE 5.20 – Résultats de la comparaison du nombre de faux amers des méthodes  $BRIEF_{GL}$  vs  $BRIEF_{\pi}$ ; FT : Rotation, Translation & Ajout du bruit

Les figures 5.18, 5.18, 5.19 et 5.20 illustrent une modélisation 3D des résultats de comparaison du nombre de faux amers sur les transformations combinées : une transformation de type rotation combinée à un bruit gaussien, ainsi qu'une transformation de type translation combinée à un bruit gaussien. Cette expérimentation consiste à l'évaluation de notre approche proposée en terme de nombre de faux amers détectés pour les quatre méthodes SURF, BRISK, BRIEF et ORB dans les deux espaces de représentation de connaissances (GL : existant vs  $\pi$  : proposée) pour les deux types de transformations combinées (rotation avec bruit et translation avec bruit).

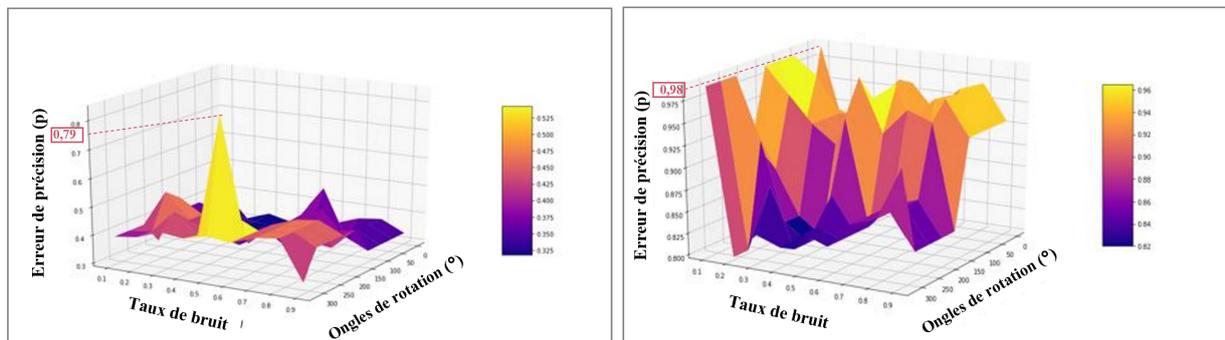
Les résultats obtenus présentent un écart important pour les quatre méthodes entre le nombre de faux amers dans un espace de représentation au niveau de gris (approche existante) et le nombre de faux amers détecté dans un espace de représentation de connaissances sémantique (approche proposée).

Ainsi, nous évaluons notre méthode en utilisant un autre critère de performance : valeur précision. Les courbes 5.21 et 5.22 illustrent une modélisation 3D du calcul de la valeur de précision pour les deux méthodes SURF et ORB dans les deux espaces de représentation des connaissances GL et  $\pi$  pour les deux types de transformations combinées (Rotation + Bruit) et (Translation + Bruit.)



(a) **SURF** au niveau pixelique (GL) ; FT : **Rotation** (b) **SURF** au niveau sémantique ( $\pi$ ) ; FT : **Rotation**

FIGURE 5.21 – Modélisation 3D des résultats de la comparaison des valeurs de précision de  $SURF_{GL}$  vs  $SURF_{\pi}$  ; FT : Rotation + Ajout du bruit



(a) **ORB** au niveau pixelique (GL) ; FT : **Rotation** (b) **ORB** au niveau sémantique ( $\pi$ ) ; FT : **Rotation**

FIGURE 5.22 – Modélisation 3D des résultats de la comparaison des valeurs de précision de  $ORB_{GL}$  vs  $ORB_{\pi}$  ; FT : Rotation + Ajout du bruit

Nous pouvons bien remarqué que notre approche de recalage possibiliste proposée présente une meilleure précision.

En effet, les résultats d'évaluation de notre approche proposée confirment que notre approche de recalage géométrique possibiliste est plus performante en terme de nombre de faux amers ainsi qu'au terme de précision, Ce qui nous amène à confirmer que notre approche de recalage possibiliste présente une meilleure performance.

### 5.4.2 Interprétation, comparaison et évaluation

Les expérimentations sont réalisées à l'aide d'une base de données d'images Quickbird 5.7 en utilisant quatre méthodes de recalage géométrique opérant sur un espace de représentation des connaissances pixelique (GL) et leurs application dans un autre espace de représentation de haut niveau semi-sémantique ( $\pi$ ). Les méthodes SURF, BRISK, ORB et BRIEF.

Les résultats obtenus montrent clairement que l'approche proposée est insensible au type de transformation et à la méthode de détection des primitives ainsi qu'à la cartographie utilisée.

L'approche proposée permet de réduire le nombre de faux amers pour toutes méthodes et pour des divers types de transformations simple ou combinées. De plus, nous pouvons remarquer que malgré les variations des paramètres des fonctions de transformation, le nombre de faux

amers reste faible pour les quatre méthodes de recalage géométrique considérées (i.e., SURF, ORB, BRIEF, BRISK).

Par conséquent, nous pouvons confirmer que l'approche de recalage possibiliste proposée apporte un grand avantage en termes de diminution du nombre de faux amers ainsi qu'une meilleure robustesse aux paramètres de transformation et au type d'images pour toutes les expérimentations; quelle que soit la méthode de recalage géométrique considéré ( $SURF_\pi$ ,  $BRISK_\pi$ ,  $BRIEF_\pi$  ou  $ORB_\pi$ ). Nous constatons également que l'approche de recalage géométrique possibiliste proposée est plus efficace pour la transformation de type translation et qu'elle est insensible au bruit. De plus, en comparant les méthodes de détection et de description des primitives ( $SURF_\pi$ ,  $BRISK_\pi$ ,  $BRIEF_\pi$  ou  $ORB_\pi$ ) nous remarquons que la méthode ORB semble la plus efficace en termes de diminution du nombre de faux amers.

Ainsi, le taux d'erreur est inférieur à 10 % par rapport aux méthodes existantes. Cet avantage est fourni en raison de l'application de la phase de projection des connaissances de l'approche proposée.

## **5.5 Application sur des images médicales : Contexte non supervisé**

Nous avons proposé une approche qui intègre deux contextes : le contexte supervisé (présenté dans les sections précédentes) où l'ensemble des classes sont données par un expert à l'aide des zones d'apprentissage et un contexte non supervisé qui nécessite un pré-traitement qui précède le processus de recalage possibiliste permettant l'identification de l'ensemble des classe thématique. Ces dernières sont les données d'entrée de notre processus de recalage.

### **5.5.1 Présentation de l'approche**

Nous proposons une approche de recalage géométrique possibiliste non supervisé permettant de limiter les problèmes de l'approche recalage géométrique existante. En fait, le processus de recalage proposé commence par une phase d'identification des objets (avec ou sans signification sémantique) à partir des images source et cible à recaler, puis recherchent la meilleure transformation permettant de faire correspondre les deux images (sur la base des primitives visuelles identifiées). Ce «processus de focalisation sémantique» permet de réduire la quantité d'informations, ainsi que les effets de bruit, lors du processus de mise en correspondance.

Notre approche proposée consiste à exploiter les avantages de la théorie de possibilité pour extraire, des connaissances semi-sémantiques liées aux objets existants à partir d'images à recaler et à conduire le processus de recalage au niveau des connaissances semi-sémantiques possibilistes. En fait, si la scène considérée comprend des classes sémantiques "M" (pour lesquelles la classification non supervisée qui permet de déterminer les centroïdes des classes sémantiques existantes), alors, le processus de projection conduit à transformer chaque image en  $M$  cartes possibilistes, où chaque carte est formée par des valeurs de possibilité de classe données.

Le nouvel espace de connaissances crée comporte l'ensemble des informations des cartes de possibilité de chacune des images source ( $Im_s$ ) et des images cibles ( $Im_t$ ) appelée aussi image transformée à partir d'une classification non supervisée.

Nous rappelons que la phase de projection des connaissances proposée consiste à minimiser le risque de conflit, lors du processus de mise en correspondance, entre les primitives extraites à la fois des images source et cible.

Les phases principale de l'approche de recalage possibiliste non supervisé sont illustré dans la figure suivante, 5.23.

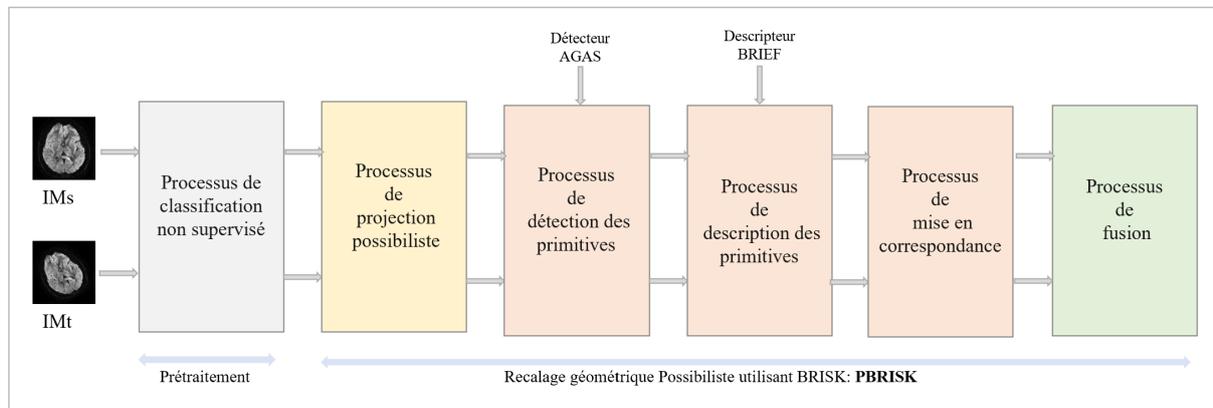


FIGURE 5.23 – Schéma global de l'approche non supervisée proposée pour le recalage des images possibilistes

1. Pré-traitement : classification non supervisée afin d'obtenir l'ensemble des classes thématique,
2. Projection des des connaissance dans un espace de représentation des connaissances non supervisé,
3. Recalage possibiliste non supervisé
  - (a) Détection des primitives au niveau de chaque carte possibiliste,
  - (b) Description des primitives détectées au niveau de chaque carte possibiliste,
  - (c) Mise en correspondance des primitives.
4. Fusion des résultats de recalage partiels.

### 5.5.2 Plan d'expérimentation

L'approche de recalage proposée est appliquée en utilisant plusieurs types de transformation définie par le protocole d'évaluation que nous proposons ; il comporte les transformations : rotation, changement d'échelle et ajout de bruit.

La figure 5.24 présente le protocole proposé pour l'évaluation de la performance de notre approche de recalage possibiliste non supervisé.

Pour chaque type de transformation utilisé, plusieurs paramètres de transformation sont utilisés.

Le processus de recalage possibiliste est présenté dans un contexte sémantique au lieu d'un contexte au niveau gris sachant que les différentes classes sont obtenues par la classification non supervisée.

L'approche de recalage possibiliste non supervisée proposée est comparée à trois méthodes de recalage classiques, qui sont SURF, BRISK et ORB. Deux critères d'évaluation, qui sont le

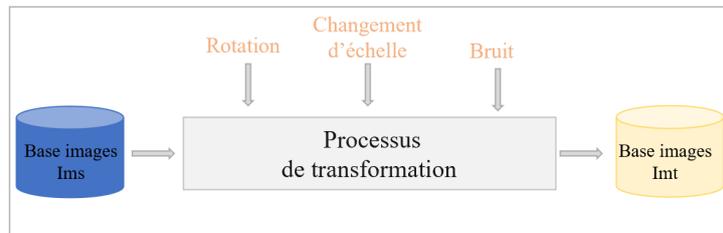


FIGURE 5.24 – Protocole d'évaluation

temps de calcul ainsi que le nombre de faux amers, sont effectués.

Les expériences sont menées à l'aide d'images médicales d'une tumeur mammaire acquise par imagerie IRM "Magnetic Resonance Imaging"

(Breast MRI dataset RIDER (<http://www.cancerimagingarchive.net/>)) 5.25.

Pour la partie expérimentale, nous considérons deux ensembles d'images (source et cible) de notre base d'images. Le processus de classification non supervisé nous a donné deux ensembles de classes thématique des deux images source  $Im_s$  et  $Im_t$  qui sont :  $C_1$ = Tumeur et  $C_2$ = Healthy skin.

Les classes sont présentées dans la figure 5.25.

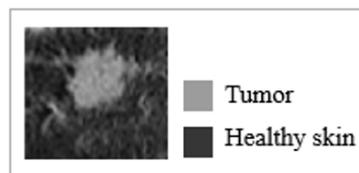
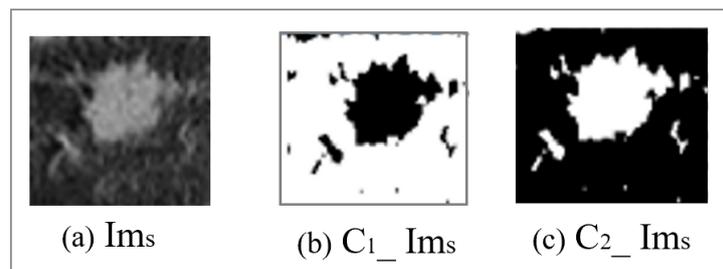


FIGURE 5.25 – Image de la tumeur mammaire

Les figures 5.26 et 5.27 présentent un exemple des cartes de possibilités des deux images à recaler.

FIGURE 5.26 – Exemple de la phase de projection possibiliste d'une coupe d'image IRM (Image source); (b) : Carte possibiliste  $C_1$ , (c) : Carte possibiliste  $C_2$ 

### 5.5.3 Expérimentations et résultats du recalage d'images possibiliste non supervisé

L'évaluation des performances de notre approche de recalage possibiliste supervisé comporte trois critères de performance qui sont comme suit, la complexité temporelle faible et le nombre de faux amers réduit. Nous avons effectué une étude comparative des méthodes  $ORB_{GL}$ ,  $SURF_{GL}$

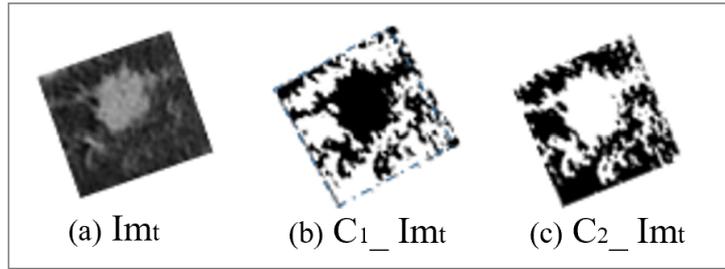
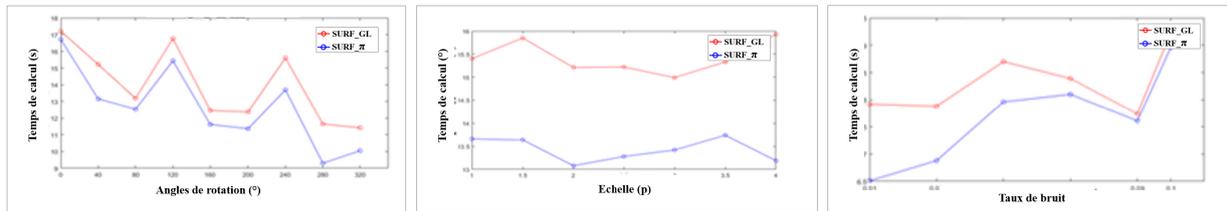


FIGURE 5.27 – Exemple de la phase de projection possibiliste d’une coupe d’image IRM (Image transformée); (b) : Carte possibiliste  $C_1$ , (c) : Carte possibiliste  $C_2$

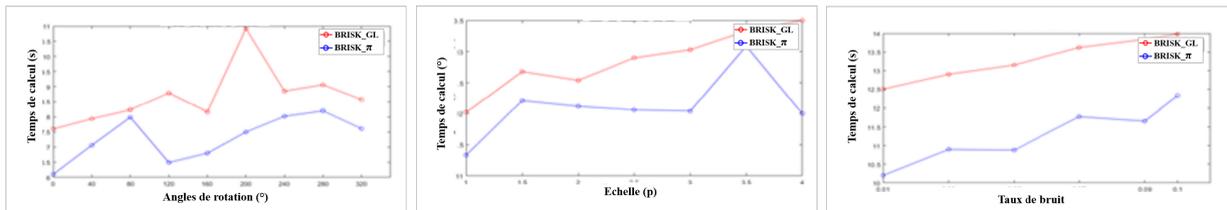
et  $BRISK_{GL}$  selon leurs espaces de représentation des connaissances existants (Niveau pixelique) avec les méthodes  $ORB_{\pi}$ ,  $SURF_{\pi}$  et  $BRISK_{\pi}$  opérant dans un espace de représentation des connaissances sémantique (approche proposée).

Les figures suivantes illustrent le temps de calcul (TC) du recalage au niveaux  $GL$  vs  $\pi$ .



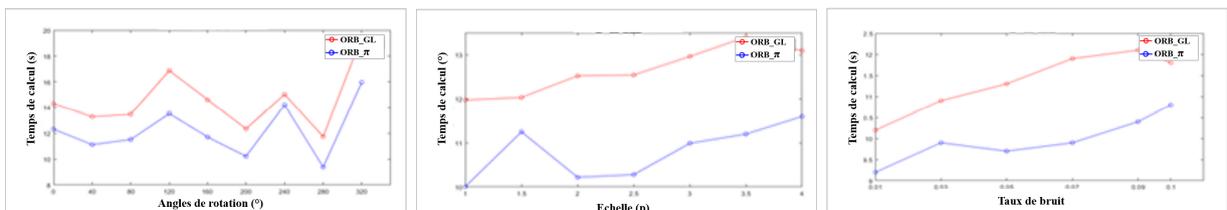
(a) TC de SURF, GL vs  $\pi$ , Rotation (b) TC de SURF, GL vs  $\pi$ , Echelle (c) TC de SURF, GL vs  $\pi$ , Bruit gaussien

FIGURE 5.28 – Évaluation du temps de calcul (TC (s)) de  $SURF_{GL}$  vs  $SURF_{\pi}$



(a) TC de BRISK, GL vs  $\pi$ , Rotation (b) TC de BRISK, GL vs  $\pi$ , Echelle (c) TC de BRISK, GL vs  $\pi$ , Bruit gaussien

FIGURE 5.29 – Évaluation du temps de calcul (TC (s)) de  $BRISK_{GL}$  vs  $BRISK_{\pi}$



(a) TC de ORB, GL vs  $\pi$ , Rotation (b) TC de ORB, GL vs  $\pi$ , Echelle (c) TC de ORB, GL vs  $\pi$ , Bruit gaussien

FIGURE 5.30 – Évaluation du temps de calcul (TC (s)) de  $ORB_{GL}$  vs  $ORB_{\pi}$

Nous avons comparé les résultats du recalage pour les transformations : rotation, changement d'échelle et ajout du bruit des méthodes de recalage géométrique SURF (Fig.5.28), BRISK (Fig.5.29) et ORB (Fig.5.30).

Toutes les figures montrent clairement que l'approche de recalage géométrique possibiliste proposée permet d'optimiser la complexité temporelle, elle permet de diminuer le temps de calcul malgré les phases de projection et de fusion rajoutées pour le recalage dans le nouvel espace de représentation des connaissances.

Nous constatons que l'approche de recalage géométrique possibiliste est plus performante en terme de complexité temporelle pour les trois types de transformations, et elle est insensible à la méthode de recalage classique considéré pour les phases de détection, description et mise en correspondance des primitives.

Dans ce qui suit, nous calculons le nombre de faux amers détecté en conservant les mêmes types de transformations ainsi que les mêmes méthodes de recalage géométrique existantes (Fig. 5.31).

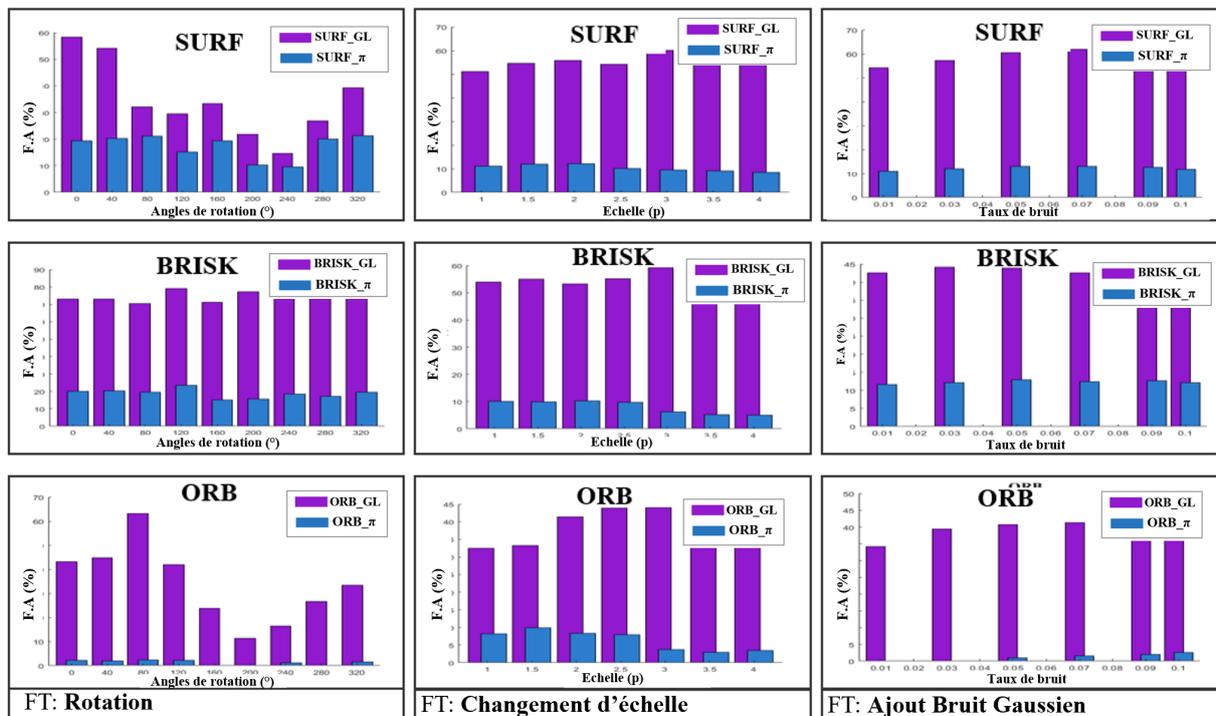


FIGURE 5.31 – Évaluation du nombre de faux amers (FA (%)) des méthodes de recalage selon l'espace de représentation des connaissances GL vs  $\pi$ , méthodes : SURF, BRISK et ORB; FT : Rotation, Échelle et Bruit

Les résultats obtenus (Fig. 5.31) présentent un grand écart entre le nombre de faux amers obtenus par le recalage géométrique au niveau de gris (GL) et le nombre de faux amers obtenus au niveau pixelique ( $\pi$ ). Nous pouvons confirmer que l'approche possibiliste proposée permet d'améliorer la performance de la qualité du recalage. Nous rappelons que la qualité du recalage est fortement liée au nombre de faux amers détecté; plus qu'on a de faux amers puisqu'on aura un recalage non fiable.

### 5.5.4 Interprétation, comparaison et évaluation

Nous avons réalisé une étude expérimentale qui intègre des divers types de détecteurs et de descripteurs afin d'évaluer leurs impacts sur la qualité du recalage dans un espace de représentation des connaissances sémantique. Pour chaque expérimentation, nous avons appliqué deux types d'expérimentations (rotation et changement d'échelle), ainsi, nous avons injecté un taux de bruit pour évaluer la sensibilité de notre approche.

Tous les résultats trouvés prouvent que l'aspect sémantique des images à recaler a un grand impact sur la performance du résultat du recalage géométrique pour des divers types de transformations et indépendamment des détecteurs ainsi qu'aux descripteurs utilisés pour la mise en correspondance des primitives.

Notre approche de recalage géométrique basée sur la théorie des possibilités dans un *contexte non supervisé* a permis d'obtenir une meilleure complexité temporelle, et une réduction du nombre de faux amers. Ainsi, elle est insensible au bruit gaussien.

## 5.6 Conclusion

Le recalage d'image présente l'un des principaux problèmes du traitement d'image. Il s'agit de la mise en correspondance d'un ensemble d'images afin de regrouper leurs informations respectives.

Toutes les méthodes de l'approche géométrique utilisent des informations au niveau de gris des deux images à recaler. Ce niveau de connaissance est fortement liée au système d'acquisition ce qui constitue la source de conflit au niveau de la mise en correspondances des primitives.

Le conflit et l'ambiguïté qui se présentent au niveau de la mise en correspondance est liée à l'imperfection de l'information issue des deux images à recaler. Pour surmonter ce problème d'incertitude nous avons proposé de construire un nouvel espace de représentation des connaissances semi-sémantique en appliquant une phase de projection de connaissances à l'aide de la théorie des possibilités.

Nous avons présenté dans ce chapitre une étude expérimentale pour les deux contextes de notre approche ; contexte supervisé et contexte non supervisé.

Nous avons pu confirmer la fiabilité et la performance de notre approche de recalage géométrique possibiliste proposée dans les deux contextes (supervisé et non supervisé) en plusieurs termes. Nous avons obtenue une complexité temporelle optimale, un nombre de faux amers réduit et une meilleure performance de la précision.

Ainsi, nous pouvons conclure notre approche est insensible au bruit, insensible au type de transformation ainsi qu'au nombre de classe thématique. Nous avons confirmé que notre approche est fiable dans des divers domaines d'applications pour les deux contextes.

# Conclusions et perspectives

Notre travail a été orienté vers l'identification d'une technique performante de recalage d'image pouvant palier aux problèmes posés par les méthodes existantes. Ce souci est à l'origine d'une demande de plus en plus pressante en systèmes d'analyse d'images multi-temporelles où la mise en correspondance de ces images est un impératif qui nécessite une grande précision.

Les différentes approches de recalage géométriques, iconiques et hybrides souffrent du problème de faux amers qu'elles génèrent. Ce problème est dû aux spécificités des systèmes d'acquisitions des deux images à recaler (image source, image cible), aux conditions particulières qui accompagnent la capture des images et aussi de la technique d'extraction des amers et leur mise en correspondance.

Les méthodes de recalage géométrique existantes considèrent les informations de la base de connaissances au niveau pixelique des deux images à recaler. Ce niveau de connaissance peut présenter plusieurs problèmes qui peuvent principalement donner un résultat de recalage non performant en terme de précision. Contrairement aux méthodes existantes en recalage qui utilisent les images à recaler comme seules de modélisation du système de transformation, nous avons introduit une nouvelle approche basée sur des sources d'information multiples qui impliquent, outre l'image source et l'image cible, d'autres sources qui résultent d'un processus de classification qui génère des cartes de possibilité.

La première contribution de ce travail réside donc dans l'approche multi-sources que nous avons adoptée pour le système de recalage. Chaque source étant représentée par une carte de possibilité extraite à travers une classification à priori, l'extraction des primitives devra donc s'appliquer sur des sources homogènes relativement à l'image cible et celle de destination ce qui favorise plus de cohérence dans la sélection et la correspondance des primitives. Ceci devra aussi éviter l'extraction de couples d'amers ayant une sémantique hétérogène.

Ainsi, l'approche proposée vise à exploiter les connaissances au niveau du capteur ainsi que les connaissances sémantiques des images afin d'attaquer le problème de réduction du nombre des faux amers. Ce ci nous permet de s'appuyer sur une base de connaissances enrichie d'informations sur la possibilité de chaque primitive à appartenir à l'une des classes considérées.

L'approche de recalage possibiliste proposée est basée sur l'intégration d'une étape initiale de projection de connaissances pour obtenir un ensemble de cartes contenant chacune un contenu unique. Nous appliquons une fusion des recalages partiels obtenus tout en gardant les phases de détection de primitives, la description des primitives ainsi que la mise en correspondances.

La deuxième contribution de ce travail consiste en la proposition d'un nouveau descripteur de point d'intérêt que nous avons appelé PBRISK. Il est inspiré de BRISK un descripteur existant

doté de caractéristiques performantes en terme de détection et de correspondance, mais limité par sa contrainte d'opérer sur les seules images cible et de destination. Notre descripteur PBRISK exploite les connaissances sémantiques introduites sous formes de cartes dans la description, l'extraction et la correspondance des points d'intérêt.

La phase de projection nécessite une phase de classification permettant de trouver l'ensemble de classes. Deux cas de figure se présentent : le contexte supervisé, où les cartes sémantiques dans les images source et cible sont connues, et le contexte non supervisé où nous n'avons pas d'informations sur le nombre de classes cherché.

Ainsi, la troisième contribution apportée par notre travail réside dans la proposition de l'architecture d'un système de recalage possibiliste basé sur une méthode supervisée, les modèles d'apprentissage (SVM) sont retenus. Ce système se base sur des distributions de possibilités calculées à travers des zones d'apprentissage définies. Il a été appliqué sur des paires d'images de télédétection et a fourni des résultats où la précision a été nettement améliorée par rapport au recalage géométrique classique.

La quatrième contribution de notre travail concerne le contexte non supervisé où nous avons proposé une architecture de système de recalage basé sur la méthode FCM-multicentroïde. L'un des problèmes contraignant dans l'application des méthodes non supervisées concerne le nombre de classes. Si des méthodes non supervisées admettent que le nombre de classes soit une entrée à l'algorithme, notre système exige une démarche totalement automatique et c'est la cas dans ce paramètre que le système doit dégager. Notre intérêt a été porté vers les indices de validité qui sont utilisés pour estimer le nombre de classes. Nous avons introduit un indice issu de l'état de l'art mais modifié pour qu'il puisse palier aux insuffisances des deux indices combinées retenus. Le système de recalage non supervisé que nous avons proposé a été testé sur des images médicales et a fourni des résultats très intéressants qui dépassent les performances des méthodes existantes.

Les deux systèmes de recalage proposés se distinguent par des performances comparés aux systèmes de recalage existants, cette performance touche à la fois la réduction significative du nombre de faux amers, la précision ainsi que le temps d'exécution. Nous soulignons aussi un facteur important relatif aux résultats fournis : les phases de projection et de fusion proposés par notre approche de recalage possibiliste n'augmente pas la complexité temporelle ; au contraire les résultats prouvent une diminution au niveau du temps de calcul. Ce qui est expliqué par les avantages que fournit la distribution de possibilité d'appartenance des points d'intérêt dans chaque carte sémantique.

Comme perspectives à ce travail les orientations sont les suivantes :

- Diversifier le choix des primitives Notre système et nos expérimentations ont focalisé sur des primitives de type point d'intérêt (pixel). Il serait intéressant d'adapter notre travail sur d'autres type de primitives, en particulier sur des segments ou des formes diverses. L'appariement de telles primitives devra simplifier considérablement le nombre d'amers et réduire ainsi les faux amers, particulièrement dans les images texturées.

- Exploitation du conflit Le problème de recalage fait apparaitre un cas important de discordance dans la phase de detection des amers. La classification doit prendre en considération le conflit généré au niveau des distributions de possibilité et réajuster les fonctions de masse dans la phase de décision.
- Recours à l'apprentissage profond. La méthode de classification supervisée que nous avons utilisé s'est limitée à SVM, un choix dicté par notre volonté de focaliser sur une méthode ayant des performances en temps et en précision. L'utilisation d'une approche basée deep-learning doit consolider le processus de classification. La phase d'apprentissage peut opérer sur des fenêtres centrées sur chaque pixel, ces fenetres (extraites pour chaque pixel de la zone d'apprentissage) formeront l'entrée du perceptron multi-couches, la sortie étant la classe correspondante. Ainsi, le réseau de neurone formé représenté par ce perceptron peut être configuré, ses poids calculés et utilisés pour classer chaque point de l'image source et destination.
- Filtrage des faux amers.

La qualité du recalage est sensiblement affectée par les faux amers. Le modèle utilisé dans la mise en correspondance peut engendrer des discordances importantes si les faux amers persistent dans les amers retenus définitivement. Un système de filtrage des faux amers est important à prévoir, il peut s'appuyer sur des critères, des règles, des contraintes formulées et explicités pour prédire les faux amers.

# Bibliographie

- [thi, 1996] (1996). New feature points based on geometric invariants for 3d image registration. *International journal of computer vision*, 18(2):121–137.
- [Acosta et al., 2018] ACOSTA, B. M. T., HEILIGENSTEIN, X., MALANDAIN, G. et BOUTHEMY, P. (2018). Intensity-based matching and registration for 3d correlative microscopy with large discrepancies. In *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, pages 493–496. IEEE.
- [Agrawal et al., 2008] AGRAWAL, M., KONOLIGE, K. et BLAS, M. R. (2008). Censure : Center surround extremas for realtime feature detection and matching. In *European conference on computer vision*, pages 102–115. Springer.
- [Alcantarilla et al., 2012] ALCANTARILLA, P. F., BARTOLI, A. et DAVISON, A. J. (2012). Kaze features. In *European conference on computer vision*, pages 214–227. Springer.
- [Alcantarilla et Solutions, 2011] ALCANTARILLA, P. F. et SOLUTIONS, T. (2011). Fast explicit diffusion for accelerated features in nonlinear scale spaces. *IEEE Trans. Patt. Anal. Mach. Intell*, 34(7):1281–1298.
- [Alsahwa, 2014] ALSAHWA, B. (2014). *Représentation d’un environnement par un système multi-capteurs : fusion et interprétation de scène*. Thèse de doctorat, Télécom Bretagne ; Université de Rennes 1.
- [Ambai et Yoshida, 2011] AMBAI, M. et YOSHIDA, Y. (2011). Card : Compact and real-time descriptors. In *2011 International Conference on Computer Vision*, pages 97–104. IEEE.
- [Amit et Kong, 1996] AMIT, Y. et KONG, A. (1996). Graphical templates for model registration. *IEEE Transactions on pattern analysis and machine intelligence*, 18(3):225–236.
- [Ardeshir, 2005] ARDESHIR, G. (2005). 2d and 3d image registration for medical, remote sensing and industrial applications.
- [Audin, 2021] AUDIN, M. (2021). Li géométrie euclidienne, généralités. In *Géométrie*, pages 51–72. EDP Sciences.
- [Baggio, 2012] BAGGIO, D. L. (2012). *Mastering OpenCV with practical computer vision projects*. Packt Publishing Ltd.
- [Bardinet et al., 2000] BARDINET, E., VIDAL, S. F., ARROYO, S. D., MALANDAIN, G. et de la BLANCA CAPILLA, N. P. (2000). Structural object matching. In *Proceedings of the 2nd International Symposium on Advanced Concepts for Intelligent Vision Systems (ACIVS 2000)*, volume 2, pages 73–77.
- [Bardol et al., 2018] BARDOL, T., SUBSOL, G., PEREZ, M.-J., GENEVIÈVE, D., LAMOUROUX, A., ANTOINE, B., CAPTIER, G., PRUDHOMME, M. et BERTRAND, M. (2018). Three-dimensional computer-assisted dissection of pancreatic lymphatic anatomy on human fetuses : a step toward automatic image alignment. *Surgical and Radiologic Anatomy*, 40(5):587–597.
- [Bay et al., 2006] BAY, H., TUYTELAARS, T. et GOOL, L. V. (2006). Surf : Speeded up robust features. In *European conference on computer vision*, pages 404–417. Springer.

- [Bde Boor, 2001] BDE BOOR, C. (2001). A practical guide to splines, revised edition.
- [Betrouni, 2009] BETROUNI, N. (2009). Le recalage en imagerie médicale : de la conception à la validation. *IRBM*, 30(2):60–71.
- [Bezdek *et al.*, 1981] BEZDEK, J. C., CORAY, C., GUNDERSON, R. et WATSON, J. (1981). Detection and characterization of cluster substructure i. linear structure : Fuzzy c-lines. *SIAM Journal on Applied Mathematics*, 40(2):339–357.
- [Bezdek *et al.*, 1984] BEZDEK, J. C., EHRLICH, R. et FULL, W. (1984). Fcm : The fuzzy c-means clustering algorithm. *Computers & geosciences*, 10(2-3):191–203.
- [Bloch, 2008] BLOCH, I. (2008). *Information Fusion in Signal and Image Processing (Digital Signal and Image Processing)*. Digital Signal and Image Processing. Wiley-ISTE, 1 édition.
- [Bloch, 2020] BLOCH, I. (2020). Recalage et fusion d’images médicales.
- [Bloch *et al.*, 2001] BLOCH, I., HUNTER, A., APPRIOU, A., AYOUN, A., BENFERHAT, S., BERNARD, P., CHOLVY, L., COOKE, R., CUPPENS, F., DUBOIS, D. *et al.* (2001). Fusion : General concepts and characteristics. *International journal of intelligent systems*, 16(10):1107–1134.
- [Bloch et Maitre, 2004] BLOCH, I. et MAITRE, H. (2004). Les méthodes de raisonnement dans les images. *Ecole Nationale Supérieure des Télécommunications-CNRS UMR*, 5141.
- [Boley, 1998] BOLEY, D. (1998). Principal direction divisive partitioning. *Data mining and knowledge discovery*, 2(4):325–344.
- [Bolon *et al.*, 1995] BOLON, P., CHASSERY, J.-M., COCQUEREZ, J.-P., DEMIGNY, D., GRAFFIGNE, C., MONTANVERT, A., PHILIPP, S., ZÉBOUDJ, R., ZERUBIA, J. et MAÎTRE, H. (1995). *Analyse d’images : filtrage et segmentation*. Masson.
- [Bookstein, 1989] BOOKSTEIN, F. L. (1989). Principal warps : Thin-plate splines and the decomposition of deformations. *IEEE Transactions on pattern analysis and machine intelligence*, 11(6):567–585.
- [Bookstein et Green, 1993] BOOKSTEIN, F. L. et GREEN, W. D. (1993). Thin-plate spline for deformations with specified derivatives. *In Mathematical Methods in Medical Imaging II*, volume 2035, pages 14–28. International Society for Optics and Photonics.
- [Borgefors, 1988] BORGEFORS, G. (1988). Hierarchical chamfer matching : A parametric edge matching algorithm. *IEEE Transactions on pattern analysis and machine intelligence*, 10(6):849–865.
- [Borgefors et di Baja, 1988] BORGEFORS, G. et di BAJA, G. S. (1988). Skeletonizing the distance transform on the hexagonal grid. *In 9th International Conference on Pattern Recognition*, pages 504–505. IEEE Computer Society.
- [Bossart, 2024] BOSSART, P.-L. (2024). *Détection de contours réguliers dans des images bruitées et texturées : association des contours actifs et d’une approche multiéchelle*. Thèse de doctorat, Grenoble INPG.
- [Boucher, 2013] BOUCHER, A. (2013). *Recalage et analyse d’un couple d’images : application aux mammographies*. Thèse de doctorat, Université René Descartes-Paris V.

- [Boustia *et al.*, 2019] BOUSTIA, F., CRESPIY, A., JANOT, K. et HERBRETEAU, D. (2019). Prise en charge endovasculaire de l'accident vasculaire cérébral ischémique aigu. *La Presse Médicale*, 48(6):664–671.
- [Bres *et al.*, 2003] BRES, S., JOLION, J.-M. et LEBOURGEOIS, F. (2003). *Traitement et analyse des images numériques*. Hermes Science Publications.
- [Broit, 1981] BROIT, C. (1981). *Optimal registration of deformed images*. University of Pennsylvania.
- [Brown, 1992] BROWN, L. G. (1992). A survey of image registration techniques. *ACM computing surveys (CSUR)*, 24(4):325–376.
- [Bürgmann *et al.*, 2000] BÜRGMANN, R., ROSEN, P. A. et FIELDING, E. J. (2000). Synthetic aperture radar interferometry to measure earth's surface topography and its deformation. *Annual review of earth and planetary sciences*, 28(1):169–209.
- [Cachier *et al.*, 2003] CACHIER, P., BARDINET, E., DORMONT, D., PENNEC, X. et AYACHE, N. (2003). Iconic feature based nonrigid registration : the pasha algorithm. *Computer vision and image understanding*, 89(2-3):272–298.
- [Calonder *et al.*, 2010] CALONDER, M., LEPETIT, V., STRECHA, C. et FUA, P. (2010). Brief : Binary robust independent elementary features. In *European conference on computer vision*, pages 778–792. Springer.
- [Caloz et Collet, 2011] CALOZ, R. et COLLET, C. (2011). *Analyse spatiale de l'information géographique*. PPUR Presses polytechniques.
- [Chailloux, 2007] CHAILLOUX, C. (2007). *Recalage d'images sonar par appariement de régions : application à la génération d'une mosaïque*. Thèse de doctorat, Télécom Bretagne.
- [Chen *et al.*, 2003] CHEN, H.-M., ARORA, M. K. et VARSHNEY, P. K. (2003). Mutual information-based image registration for remote sensing data. *International Journal of Remote Sensing*, 24(18):3701–3706.
- [Chen et Tian, 2009] CHEN, J. et TIAN, J. (2009). Real-time multi-modal rigid registration based on a novel symmetric-sift descriptor. *Progress in Natural Science*, 19(5):643–651.
- [Chen *et al.*, 2021] CHEN, Y., WANG, J., LIU, S., CHEN, X., XIONG, J., XIE, J. et YANG, K. (2021). Retracted : Multiscale fast correlation filtering tracking algorithm based on a feature fusion model. *Concurrency and Computation : Practice and Experience*, 33(15):e5533.
- [Chuang *et al.*, 2016] CHUANG, C.-H., JACKSON, S. E. et JIANG, Y. (2016). Can knowledge-intensive teamwork be managed? examining the roles of hrm systems, leadership, and tacit knowledge. *Journal of management*, 42(2):524–554.
- [Correas et Pol, 2012] CORREAS, J.-M. et POL, S. (2012). Nouveautés dans l'imagerie des hépatopathies : de l'imagerie anatomique à l'imagerie structurelle et fonctionnelle en ultrasons. *La Presse Médicale*, 41(2):153–168.
- [Cottet *et al.*, 2021] COTTET, G.-H., MAITRE, E. et MILCENT, T. (2021). Méthodes level set et interfaces lagrangiennes. In *Méthodes Level Set pour l'interaction fluide-structure*, pages 1–35. Springer.

- [Dang *et al.*, 2012] DANG, Q.-V., MOUYSET, S. et MORIN, G. (2012). Détection de similarités de surfaces paramétriques. *Revue Electronique Francophone d'Informatique Graphique*, 6(2).
- [De La Vega, 1967] DE LA VEGA, W. F. (1967). Techniques de classification automatique utilisant un indice de ressemblance. *Revue Française de sociologie*, pages 506–520.
- [Delhay, 2006] DELHAY, B. (2006). *Estimation spatio-temporelle de mouvement et suivi de structures déformables : application à l'imagerie dynamique du coeur et du thorax*. Thèse de doctorat, Lyon, INSA.
- [Dempster *et al.*, 1977] DEMPSTER, A. P., LAIRD, N. M. et RUBIN, D. B. (1977). Maximum likelihood from incomplete data via the em algorithm. *Journal of the Royal Statistical Society : Series B (Methodological)*, 39(1):1–22.
- [Derpanis, 2004] DERPANIS, K. G. (2004). The harris corner detector. *York University*, 2.
- [Descombes, 1993] DESCOMBES, X. (1993). *Champs Markoviens en analyse d'images*. Thèse de doctorat, Paris, ENST.
- [Dhahbi *et al.*, 2008] DHAHBI, S., BARHOUMI, W. et ZAGROUBA, E. (2008). Une approche rapide pour un recalage non-rigide des mammographies. *In Workshop en Informatiques et Applications, Tozeur, Tunisia*, pages 45–50.
- [Dunn, 1973] DUNN, J. C. (1973). A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters.
- [D'IMAGES, 2018] D'IMAGES, A. (2018). Principes généraux de l'analyse d'images numériques. *La dendroécologie : Principes, méthodes et applications*, page 284.
- [Favre *et al.*, 2021] FAVRE, K., PRESSIGOUT, M., MARCHAND, E. et MORIN, L. (2021). Recalage basé plans de nuages de points pour la navigation dans des environnements structurés. *In ORASIS 2021*.
- [Fjørtoft, 1999] FJØRTOFT, R. (1999). *Segmentation d'images radar par detection de contours*. Thèse de doctorat, Toulouse, INPT.
- [Frangi *et al.*, 2001] FRANGI, A. F., NIESSEN, W. J. et VIERGEVER, M. A. (2001). Three-dimensional modeling for functional analysis of cardiac images, a review. *IEEE transactions on medical imaging*, 20(1):2–5.
- [Gastellu-Etchegorry, 2008] GASTELLU-ETCHEGORRY, J. (2008). Acquisition et traitement d'image numérique. *IUT-Département de mesures physique, Université Paul Sabatier*.
- [Gee *et al.*, 1997] GEE, J. C., HAYNOR, D. R., BRIQUER, L. L. et BAJCSY, R. K. (1997). Advances in elastic matching theory and its implementation. *In CVRMed-MRCAS'97*, pages 63–72. Springer.
- [GHORBEL *et al.*, 2009] GHORBEL, S., KHALFALLAH, A. et BOUHLEL, M. S. (2009). Etude et evaluation des techniques de corrélation et corrélation de phase : Application pour le recalage des images. *In 5th International Conference : Sciences of Electronic, Technologies of Information and Telecommunications SETIT March*, pages 22–26.
- [Giraud *et al.*, 2020] GIRAUD, R., BOYER, M. et CLÉMENT, M. (2020). Algorithme de correspondance de superpatches multi-échelles basé sur des descripteurs duals de superpixels. *In Reconnaissance des Formes, Image, Apprentissage et Perception (RFIAP 2020)*.

- [Gobin, 2021] GOBIN, G. (2021). *Localisation d'un robot humanoïde TALOS par information géométrique et visuelle combinée à l'apprentissage*. Thèse de doctorat, Toulouse 3 Paul Sabatier.
- [Goldberg, 1989] GOLDBERG, D. E. (1989). Optimization, and machine learning. *Genetic algorithms in Search*.
- [Guerroumi, 2019] GUERROUMI, N. (2019). *Segmentation automatique par apprentissage profond de la colonne vertébrale scoliotique à partir d'images de résonance magnétique*. Thèse de doctorat, École de technologie supérieure.
- [Guha et al., 1998] GUHA, S., RASTOGI, R. et SHIM, K. (1998). Cure : An efficient clustering algorithm for large databases. *ACM Sigmod record*, 27(2):73–84.
- [Guilloteau, 2021] GUILLOTEAU, C. (2021). *Fusion rapide d'images multispectrales et hyperspectrales en astronomie infrarouge*. Thèse de doctorat.
- [Guo et al., 2006] GUO, Y., SURI, J. et SIVARAMAKRISHNA, R. (2006). Image registration for breast imaging : a review. In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, pages 3379–3382. IEEE.
- [Haouas et al., 2019] HAOUAS, F., SOLAIMAN, B., DHIAF, Z. B., HAMOUDA, A. et BSAIES, K. (2019). Multi-temporal image change mining based on evidential conflict reasoning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151:59–75.
- [Harrathi et Calabretto, 2006] HARRATHI, R. et CALABRETTO, S. (2006). Un modèle de qualité de l'information. In *Extraction et gestion des connaissances (EGC'2006), Actes des sixièmes journées Extraction et Gestion des Connaissances, Lille, France, 17-20 janvier 2006, 2 Volumes*, pages 299–304.
- [Hill et al., 2001] HILL, D. L., BATCHELOR, P. G., HOLDEN, M. et HAWKES, D. J. (2001). Medical image registration. *Physics in medicine & biology*, 46(3):R1.
- [Höfle et Pfeifer, 2007] HÖFLE, B. et PFEIFER, N. (2007). Correction of laser scanning intensity data : Data and model-driven approaches. *ISPRS journal of photogrammetry and remote sensing*, 62(6):415–433.
- [Hohweiller, 2019] HOHWEILLER, T. (2019). *Méthodes de décomposition non-linéaire pour l'imagerie X spectrale*. Thèse de doctorat, Université de Lyon.
- [Horn et Schunck, 1981] HORN, B. K. et SCHUNCK, B. G. (1981). Determining optical flow. *Artificial intelligence*, 17(1-3):185–203.
- [Huet et Philipp, 1998] HUET, F. et PHILIPP, S. (1998). Fusion of images after segmentation by various operators and interpretation by a multi-scale fuzzy classification. In *Pattern Recognition, International Conference on*, volume 2, pages 1843–1843. IEEE Computer Society.
- [Ilyas, 2021] ILYAS, T. (2021). *Recalage des images médicales par apprentissage profond*. Thèse de doctorat, Université laarbi tebessi tebessa.
- [Ishibuchi et Nakashima, 2001] ISHIBUCHI, H. et NAKASHIMA, T. (2001). Effect of rule weights in fuzzy rule-based classification systems. *IEEE Transactions on Fuzzy Systems*, 9(4):506–515.
- [Jannin et al., 2001] JANNIN, P., GROVA, C. et GIBAUD, B. (2001). Fusion de données en imagerie médicale : revue méthodologique basée sur le contexte clinique. *ITBM-RBM*, 22(4):196–215.

- [Jędzierowska *et al.*, 2019] JĘDZIEROWSKA, M., KOPROWSKI, R., WILCZYŃSKI, S. et KRYSIK, K. (2019). A new method for detecting the outer corneal contour in images from an ultra-fast scheimpflug camera. *BioMedical Engineering OnLine*, 18(1):1–22.
- [Journet *et al.*, 2008] JOURNET, N., MULLOT, R., EGLIN, V. et RAMEL, J.-Y. (2008). Analyse d’images de documents anciens : une approche texture. *Traitement du signal*, 24(6):461–479.
- [KAAZAOUI et KAAZAOUI, 2018] KAAZAOUI, A. et KAAZAOUI, K. (2018). La fusion d’image multifocale.
- [Karypis *et al.*, 1999] KARYPIS, G., HAN, E.-H. et KUMAR, V. (1999). Chameleon : Hierarchical clustering using dynamic modeling. *Computer*, 32(8):68–75.
- [Kaufman et Rousseeuw, 2009] KAUFMAN, L. et ROUSSEEUW, P. J. (2009). *Finding groups in data : an introduction to cluster analysis*. John Wiley & Sons.
- [Khan *et al.*, 2021] KHAN, M. A., MITTAL, M., GOYAL, L. M. et ROY, S. (2021). A deep survey on supervised learning based human detection and activity classification methods. *Multimedia Tools and Applications*, 80(18):27867–27923.
- [Kim *et al.*, 2005] KIM, K., NERETTI, N. et INTRATOR, N. (2005). Mosaicing of acoustic camera images. *IEE Proceedings-Radar, Sonar and Navigation*, 152(4):263–270.
- [Kirkpatrick *et al.*, 1983] KIRKPATRICK, S., GELATT JR, C. D. et VECCHI, M. P. (1983). Optimization by simulated annealing. *science*, 220(4598):671–680.
- [Kjer et Wilm, 2010] KJER, H. M. et WILM, J. (2010). Evaluation of surface registration algorithms for pet motion correction. B.S. thesis, Citeseer.
- [Klette, 2014] KLETTE, R. (2014). *Concise computer vision*, volume 1. Springer.
- [Klypin *et al.*, 2002] KLYPIN, A., ZHAO, H. et SOMERVILLE, R. S. (2002).  $\Lambda$ cdm-based models for the milky way and m31. i. dynamical models. *The Astrophysical Journal*, 573(2):597.
- [Lavric *et al.*, 2020] LAVRIC, A., POPA, V., TAKAHASHI, H. et YOUSEFI, S. (2020). Detecting keratoconus from corneal imaging data using machine learning. *IEEE Access*, 8:149113–149121.
- [Leborgne, 2016] LEBORGNE, A. (2016). *Appariement de formes basé sur une squelettisation hiérarchique*. Thèse de doctorat, Université de Lyon.
- [Li, 2021] LI, M. (2021). *Approximation géométrique de scènes structurées à partir d’images*. Thèse de doctorat, Université Côte d’Azur.
- [Liu *et al.*, 2021] LIU, Y., PAN, S., JIN, M., ZHOU, C., XIA, F. et YU, P. S. (2021). Graph self-supervised learning : A survey. *arXiv preprint arXiv :2103.00111*.
- [Liu *et al.*, 2018] LIU, Y., ZHANG, H., GUO, H. et XIONG, N. N. (2018). A fast-brisk feature detector with depth information. *Sensors*, 18(11):3908.
- [Lopes *et al.*, 2010] LOPES, R., DUBOIS, P., BHOURI, I., AKKARI-BETTAIEB, H., MAOUCHE, S. et BETROUNI, N. (2010). La géométrie fractale pour l’analyse de signaux médicaux : état de l’art. *IRBM*, 31(4):189–208.
- [Loucif et Tighuiouart, 2019] LOUCIF, M. et TIGHUIOUART, B. (2019). A combined hierarchical algorithm of mammograms registration using mutual information and a point based matching approach. *International Journal of Biomedical Engineering and Technology*, 29(3):293–307.

- [Lowe, 2004] LOWE, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2):91–110.
- [MacQueen, 1967] MACQUEEN, J. (1967). Classification and analysis of multivariate observations. In *5th Berkeley Symp. Math. Statist. Probability*, pages 281–297.
- [Maintz et al., 1998] MAINTZ, J. A., MEIJERING, E. H. et VIERGEVER, M. A. (1998). General multimodal elastic registration based on mutual information. In *Medical Imaging 1998 : Image Processing*, volume 3338, pages 144–154. International Society for Optics and Photonics.
- [Maintz et Viergever, 1998] MAINTZ, J. A. et VIERGEVER, M. A. (1998). A survey of medical image registration. *Medical image analysis*, 2(1):1–36.
- [Malandain, 2006] MALANDAIN, G. (2006). Les mesures de similarité pour le recalage des images médicales. habilitation à diriger des recherches, université nice sophia-antipolis. *Mars*.
- [Malandain et al., 1994] MALANDAIN, G., FERNÁNDEZ-VIDAL, S. et ROCCHISANI, J.-M. (1994). Improving registration of 3-d medical images using a mechanical based method. In *European Conference on Computer Vision*, pages 130–136. Springer.
- [Mangin, 1995] MANGIN, J.-F. (1995). *Mise en correspondance d'images m edicales 3D multi-modalit es multi-individus pour la corr elation anatomo-fonctionnelle c er ebrale*. Thèse de doctorat, PhD thesis, Ecole Nationale Sup erieure des T el ecommunications.
- [Mangin et al., 2004] MANGIN, J.-F., RIVIERE, D., CACHIA, A., DUCHESNAY, E., COINTEPAS, Y., PAPADOPOULOS-ORFANOS, D., SCIFO, P., OCHIAI, T., BRUNELLE, F. et RÉGIS, J. (2004). A framework to study the cortical folding patterns. *Neuroimage*, 23:S129–S138.
- [Marquardt, 1963] MARQUARDT, D. W. (1963). An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics*, 11(2): 431–441.
- [Martin et al., 2008] MARTIN, A., JOUSSELME, A. et OSSWALD, C. (2008). Conflict measure for the discounting operation on belief functions. In *11th International Conference on Information Fusion, FUSION 2008, Cologne, Germany, June 30 - July 3, 2008*, pages 1–8. IEEE.
- [Marzouka et al., 2020a] MARZOUKA, W. B., SOLAIMAN, B., HAMMOUDA, A., DHIEF, Z. B. et BSAÏES, K. (2020a). Possibilistic brisk method for an efficient registration (pbrisk). In *2020 5th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*, pages 1–6. IEEE.
- [Marzouka et al., 2020b] MARZOUKA, W. B., SOLAIMAN, B., HAMMOUDA, A., DHIAF, Z. B. et BSAÏES, K. (2020b). Comparative study of feature detector and descriptor methods for registration. In *Twelfth International Conference on Machine Vision (ICMV 2019)*, volume 11433, page 114333H. International Society for Optics and Photonics.
- [Masood et Ali Al-Jumaily, 2013] MASOOD, A. et ALI AL-JUMAILY, A. (2013). Computer aided diagnostic support system for skin cancer : a review of techniques and algorithms. *International journal of biomedical imaging*, 2013.
- [Massonnet et Feigl, 1998] MASSONNET, D. et FEIGL, K. L. (1998). Radar interferometry and its application to changes in the earth's surface. *Reviews of geophysics*, 36(4):441–500.

- [Matrix, 1992] MATRIX, O. C.-o. (1992). Matrice de co-occurrence optimale pour la segmentation automatique d'images ultrasonores. *Traitement du Signal*, 9(4).
- [Menasria et Bennia, 2018] MENASRIA, A. et BENNIA, A. (2018). *Développement des techniques de segmentation et de reconnaissance d'écriture arabe manuscrite*. Thèse de doctorat, .
- [Meurée, 2013] MEURÉE, C. (2013). *Recalage d'images du fond d'oeil pour la construction d'un atlas des structures anatomiques de la rétine*. Thèse de doctorat, École Polytechnique de Montréal.
- [Mikolajczyk et Schmid, 2005] 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 et al., 1993] MILLER, M. I., CHRISTENSEN, G. E., AMIT, Y. et GRENANDER, U. (1993). Mathematical textbook of deformable neuroanatomies. *Proceedings of the National Academy of Sciences*, 90(24):11944–11948.
- [Miller et al., 1999] MILLER, M. I., JOSHI, S. C. et CHRISTENSEN, G. E. (1999). Large deformation fluid diffeomorphisms for landmark and image matching. In *Brain Warping*, pages 115–131. University of Iowa.
- [Montagnat, 1999] MONTAGNAT, J. (1999). *Modèles déformables pour la segmentation et la modélisation d'images médicales 3D et 4D*. Thèse de doctorat, Université Nice Sophia Antipolis.
- [Montagnat et al., 1999] MONTAGNAT, J., DELINGETTE, H. et MALANDAIN, G. (1999). Cylindrical echocardiographic image segmentation based on 3d deformable models. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 168–175. Springer.
- [Moumjid et al., 2009] MOUMJID, N., PROTIERE, C., MORELLE, M., BREMOND, A., MIGNOTTE, H., FAURE, C., MEUNIER, A., CARRERE, M.-O., RANCHÈRE-VINCE, D., DECOUVELAERE, A.-V. et al. (2009). La prise de décision partagée dans la rencontre médecin-patient : évolution récente et état des lieux dans le cancer du sein en france. *Journal d'économie médicale*, 27(3):134–145.
- [Ng et Henikoff, 2003] NG, P. C. et HENIKOFF, S. (2003). Sift : Predicting amino acid changes that affect protein function. *Nucleic acids research*, 31(13):3812–3814.
- [O'brien, 2000] O'BRIEN, J. A. (2000). *Introduction to information systems*. McGraw-Hill Higher Education.
- [Pagoulatos et al., 2000] PAGOULATOS, N., HAYNOR, D. R. et KIM, Y. (2000). Image-based registration of ultrasound and magnetic resonance images : a preliminary study. In *Medical Imaging 2000 : Image Display and Visualization*, volume 3976, pages 156–164. International Society for Optics and Photonics.
- [Panigrahi et al., 2021] PANIGRAHI, R., BORAH, S., BHOI, A. K., IJAZ, M. F., PRAMANIK, M., JHAVERI, R. H. et CHOWDHARY, C. L. (2021). Performance assessment of supervised classifiers for designing intrusion detection systems : a comprehensive review and recommendations for future research. *Mathematics*, 9(6):690.

- [Papathanassiou *et al.*, 2009] PAPANATHANASSIOU, D., BRUNA-MURAILLE, C., JOUANNAUD, C., GAGNEUX-LEMOUSSU, L., ESCHARD, J.-P. et LIEHN, J.-C. (2009). Tomographie d'émission monophotonique couplée au scanner et pathologie osseuse. *Revue du rhumatisme*, 76(9):843–850.
- [Pelizzari *et al.*, 1989] PELIZZARI, C. A., CHEN, G., SPELBRING, D. R., WEICHSELBAUM, R. R. et CHEN, C.-T. (1989). Accurate three-dimensional registration of ct, pet, and/or mr images of the brain. *Journal of computer assisted tomography*, 13(1):20–26.
- [Pestova, 2018] PESTOVA, V. (2018). *Coefficients de fiabilité et approche hiérarchique pour la détection et le dénombrement de petits objets dans une vidéo*. Thèse de doctorat, Université de Bordeaux.
- [Petitjean, 2013] PETITJEAN, C. (2013). Le recalage d'images.
- [Pflug et Busch, 2012] PFLUG, A. et BUSCH, C. (2012). Ear biometrics : a survey of detection, feature extraction and recognition methods. *IET biometrics*, 1(2):114–129.
- [Pichon *et al.*, 2012] PICHON, F., DUBOIS, D. et DENGÈUX, T. (2012). Relevance and truthfulness in information correction and fusion. *International Journal of Approximate Reasoning*, 53(2): 159 – 175. Theory of Belief Functions (BELIEF 2010).
- [Poreba et Goulette, 2014] POREBA, M. et GOULETTE, F. (2014). Recalage rigide de relevés laser par mise en correspondance robuste basée sur des segments. *Revue Française de Photogrammétrie et de Télédétection*, (207):3–17.
- [Prathap *et al.*, 2016] PRATHAP, K. S. V., JILANI, S. et REDDY, P. R. (2016). A critical review on image mosaicing. In *2016 International Conference on Computer Communication and Informatics (ICCCI)*, pages 1–8. IEEE.
- [Press *et al.*, 2007] PRESS, W. H., TEUKOLSKY, S. A., VETTERLING, W. T. et FLANNERY, B. P. (2007). *Numerical recipes 3rd edition : The art of scientific computing*. Cambridge university press.
- [Radouan *et al.*, 2020] RADOUAN, D., VINCENT, B., DAVID, B. et ERIC, M. (2020). Rigid registration of monomodal and multimodal images for wood pieces analysis. In *2020 IEEE 4th International Conference on Image Processing, Applications and Systems (IPAS)*, pages 192–198. IEEE.
- [Rangarajan *et al.*, 1997] RANGARAJAN, A., CHUI, H. et BOOKSTEIN, F. L. (1997). The softassign procrustes matching algorithm. In *Biennial International Conference on Information Processing in Medical Imaging*, pages 29–42. Springer.
- [Rangarajan *et al.*, 1999] RANGARAJAN, A., CHUI, H. et DUNCAN, J. S. (1999). Rigid point feature registration using mutual information. *Medical Image Analysis*, 3(4):425–440.
- [Rao, 2019] RAO, S. S. (2019). *Engineering optimization : theory and practice*. John Wiley & Sons.
- [Reichert *et al.*, 2007] REICHERT, S., GASS, R. et ANDRÈS, E. (2007). Analyse des sons auscultatoires pulmonaires. *Irbm*, 28(3-4):169–180.
- [Roche *et al.*, 2000] ROCHE, A., MALANDAIN, G. et AYACHE, N. (2000). Unifying maximum likelihood approaches in medical image registration. *International Journal of Imaging Systems and Technology*, 11(1):71–80.

- [Roche *et al.*, 1998] ROCHE, A., MALANDAIN, G., PENNEC, X. et AYACHE, N. (1998). The correlation ratio as a new similarity measure for multimodal image registration. *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 1115–1124. Springer.
- [Rogova et Bosse, 2010] ROGOVA, G. L. et BOSSE, E. (2010). Information quality in information fusion. *In Information Fusion (FUSION), 2010 13th Conference on*, pages 1–8. IEEE.
- [Rohlfing *et al.*, 2003] ROHLFING, T., MAURER, C. R., BLUEMKE, D. A. et JACOBS, M. A. (2003). Volume-preserving nonrigid registration of mr breast images using free-form deformation with an incompressibility constraint. *IEEE transactions on medical imaging*, 22(6):730–741.
- [Rohr, 2001] ROHR, K. (2001). *Landmark-based image analysis : using geometric and intensity models*, volume 21. Springer Science & Business Media.
- [Rosen *et al.*, 2000] ROSEN, P. A., HENSLEY, S., JOUGHIN, I. R., LI, F. K., MADSEN, S. N., RODRIGUEZ, E. et GOLDSTEIN, R. M. (2000). Synthetic aperture radar interferometry. *Proceedings of the IEEE*, 88(3):333–382.
- [Rubeaux, 2011] RUBEAUX, M. (2011). *Approximation de l'Information Mutuelle basée sur le développement d'Edgeworth : application au recalage d'images médicales*. Thèse de doctorat, Université Rennes 1.
- [Rucklidge, 1996] RUCKLIDGE, W. (1996). *Efficient visual recognition using the Hausdorff distance*. Springer.
- [Salaün *et al.*, 2019] SALAÜN, P.-Y., ABGRAL, R., MALARD, O., QUERELLOU-LEFRANC, S., QUÉRÉ, G., WARTSKI, M., CORIAT, R., HINDIÉ, E., TAIEB, D., TABARIN, A. *et al.* (2019). Actualisation des recommandations de bonne pratique clinique pour l'utilisation de la tep en cancérologie. *Bulletin du Cancer*, 106(3):262–274.
- [Schnabel *et al.*, 2001] SCHNABEL, J. A., RUECKERT, D., QUIST, M., BLACKALL, J. M., CASTELLANO-SMITH, A. D., HARTKENS, T., PENNEY, G. P., HALL, W. A., LIU, H., TRUWIT, C. L. *et al.* (2001). A generic framework for non-rigid registration based on non-uniform multi-level free-form deformations. *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 573–581. Springer.
- [Sederberg et Parry, 1986] SEDERBERG, T. W. et PARRY, S. R. (1986). Free-form deformation of solid geometric models. *In Proceedings of the 13th annual conference on Computer graphics and interactive techniques*, pages 151–160.
- [Settouti, 2011] SETTOUTI, N. (2011). Renforcement de l'apprentissage structurel pour la reconnaissance du diabète.
- [Shan *et al.*, 2018] SHAN, H., ZHANG, Y., YANG, Q., KRUGER, U., KALRA, M. K., SUN, L., CONG, W. et WANG, G. (2018). 3-d convolutional encoder-decoder network for low-dose ct via transfer learning from a 2-d trained network. *IEEE transactions on medical imaging*, 37(6):1522–1534.
- [Simmons et Voss, 1998] SIMMONS, N. B. et VOSS, R. S. (1998). The mammals of paracou, french guiana, a neotropical lowland rainforest fauna. part 1, bats. *bulletin of the amnh* ; no. 237.

- [Sneath *et al.*, 1973] SNEATH, P. H., SOKAL, R. R. *et al.* (1973). *Numerical taxonomy. The principles and practice of numerical classification.*
- [Tarel, 1996] TAREL, J.-P. (1996). *Recalage géométrique avec plusieurs prototypes.* Thèse de doctorat, INRIA.
- [Taylor *et al.*, 2016] TAYLOR, R. H., MENCIASSI, A., FICHTINGER, G., FIORINI, P. et DARIO, P. (2016). Medical robotics and computer-integrated surgery. In *Springer handbook of robotics*, pages 1657–1684. Springer.
- [Thirion, 1998] THIRION, J.-P. (1998). Image matching as a diffusion process : an analogy with maxwell’s demons. *Medical image analysis*, 2(3):243–260.
- [Todoran, 2014] TODORAN, I. (2014). *Etude dynamique de la qualité de l’information et des données d’un système d’information complexe. (Dynamic data and information quality evaluation in complex information systems).* Thèse de doctorat, University of Rennes 1, France.
- [Touil et Kalti, 2016] TOUIL, A. et KALTI, K. (2016). Iterative fuzzy segmentation for an accurate delimitation of the breast region. *Computer methods and programs in biomedicine*, 132:137–147.
- [Uttama *et al.*, 2005] UTTAMA, S., LOONIS, P., DELALANDRE, M. et OGIER, J.-M. (2005). Segmentation and retrieval of ancient graphic documents. In *International Workshop on Graphics Recognition*, pages 88–98. Springer.
- [Van Den Elsen *et al.*, 1994] VAN DEN ELSSEN, P. A., POL, E.-J. D., SUMANAWEEERA, T. S., HEMLER, P. F., NAPEL, S. et ADLER, J. R. (1994). Grey value correlation techniques used for automatic matching of ct and mr brain and spine images. In *Visualization in Biomedical Computing 1994*, volume 2359, pages 227–237. SPIE.
- [Vauclin *et al.*, 2010] VAUCLIN, S., GARDIN, I., DOYEUX, K., HAPDEY, S., EDET-SANSON, A. et VERA, P. (2010). Segmentation des images tep au 18f-fdg. principe et revue de la littérature. *Médecine Nucléaire*, 34(6):358–369.
- [Wang et Strong, 1996] WANG, R. Y. et STRONG, D. M. (1996). Beyond accuracy : What data quality means to data consumers. *Journal of management information systems*, 12(4):5–33.
- [West *et al.*, 1997] WEST, J., FITZPATRICK, J. M., WANG, M. Y., DAWANT, B. M., MAURER JR, C. R., KESSLER, R. M., MACIUNAS, R. J., BARILLOT, C., LEMOINE, D., COLLIGNON, A. *et al.* (1997). Comparison and evaluation of retrospective intermodality brain image registration techniques. *Journal of computer assisted tomography*, 21(4):554–568.
- [Wijaya *et al.*, 2022] WIJAYA, I. K., TAHIR, M. Y., TALIB, M. T., TASA, H. et MULYANI, S. (2022). The effect of brisk walking on blood pressure in hypertension patients : A literature review. *KnE Life Sciences*, pages 327–334.
- [Woods *et al.*, 1992] WOODS, R. P., CHERRY, S. R. et MAZZIOTTA, J. C. (1992). Rapid automated algorithm for aligning and reslicing pet images. *Journal of computer assisted tomography*, 16(4):620–633.
- [Xia *et al.*, 2013] XIA, R., ZHAO, J. et LIU, Y. (2013). A robust feature-based registration method of multimodal image using phase congruency and coherent point drift. In *MIPPR 2013 : Pattern Recognition and Computer Vision*, volume 8919, page 891903. International Society for Optics and Photonics.

- [Xu et Wunsch, 2005] XU, R. et WUNSCH, D. (2005). Survey of clustering algorithms. *IEEE Transactions on neural networks*, 16(3):645–678.
- [Yang et Cheng, 2013] YANG, X. et CHENG, K.-T. T. (2013). Local difference binary for ultra-fast and distinctive feature description. *IEEE transactions on pattern analysis and machine intelligence*, 36(1):188–194.
- [Zadeh, 1968] ZADEH, L. A. (1968). Probability measures of fuzzy events. *Journal of mathematical analysis and applications*, 23(2):421–427.
- [ZAGROUBA et DHIAF, ] ZAGROUBA, E. et DHIAF, Z. B. Approche hybride de reconstruction de facettes planes 3d.
- [Zebker, 2000] ZEBKER, H. A. (2000). Studying the earth with interferometric radar. *Computing in Science & Engineering*, 2(3):52–60.
- [Zhang et al., 1999] ZHANG, B., HSU, M. et DAYAL, U. (1999). K-harmonic means-a data clustering algorithm. *Hewlett-Packard Labs Technical Report HPL-1999-124*, 55.
- [Zhang et al., 2015] ZHANG, J., WANG, J., WANG, X. et FENG, D. (2015). Multimodal image registration with joint structure tensor and local entropy. *International journal of computer assisted radiology and surgery*, 10(11):1765–1775.
- [Zhang et al., 2005] ZHANG, L., LI, D. et TANG, W. H. (2005). Reliability of bored pile foundations considering bias in failure criteria. *Canadian Geotechnical Journal*, 42(4):1086–1093.
- [Zhang, 1993] ZHANG, Z. (1993). *Le problème de la mise en correspondance : l'état de l'art*. Thèse de doctorat, INRIA.
- [Zhang, 1994] ZHANG, Z. (1994). Iterative point matching for registration of free-form curves and surfaces. *International journal of computer vision*, 13(2):119–152.
- [Zimmermann, 2021] ZIMMERMANN, R. (2021). Chapitre 5. l'imagerie tep : la tomographie par émission de positons. *In La médecine nucléaire*, pages 69–80h. EDP Sciences.
- [Zucker, 1976] ZUCKER, S. W. (1976). Region growing : Childhood and adolescence. *Computer graphics and image processing*, 5(3):382–399.

---

**Titre :** Traitement possibiliste d'images, application au recalage d'images

**Mots clés :** Recalage géométrique possibiliste, théorie des possibilités, cartes de possibilités, base de connaissance semi-sémantique, classe sémantique, projection des connaissances, classification supervisée possibiliste, clustering possibiliste.

**Résumé :** Dans ce travail, nous proposons un système de recalage géométrique possibiliste qui fusionne les connaissances sémantiques et les connaissances au niveau du gris des images à recaler. Les méthodes de recalage géométrique existantes se reposent sur une analyse des connaissances au niveau des capteurs lors de la détection des primitives ainsi que lors de la mise en correspondance. L'évaluation des résultats de ces méthodes de recalage géométrique présente des limites au niveau de la perfection de la précision causées par le nombre important de faux amers. L'idée principale de notre approche proposée est de transformer les deux images à recaler en un ensemble de projections issues des images originales (source et cible). Cet ensemble est composé des images nommées « cartes de possibilité », dont chaque carte comporte un seul contenu et présente une distribution possibiliste d'une classe sémantique des deux images originales. Le système de recalage géométrique basé sur la théorie de possibilités proposé présente deux contextes : un contexte supervisé et un contexte non supervisé. Pour le premier cas de figure nous proposons une méthode de classification supervisée basée sur la théorie des possibilités utilisant les modèles d'apprentissage. Pour le contexte non supervisé, nous proposons une méthode de clustering possibiliste utilisant la méthode FCM-multicentroïde. Les deux méthodes proposées fournissent en résultat les ensembles de classes sémantiques des deux images à recaler. Nous créons par la suite, les bases de connaissances pour le système de recalage possibiliste proposé. Nous avons amélioré la qualité du recalage géométrique existant en termes de perfection de précision, de diminution du nombre de faux amers et d'optimisation de la complexité temporelle.

---

**Title :** Possibilistic image processing, application to image registration

**Keywords :** Possibilistic geometric registration, possibility theory, possibility maps, semi-semantic knowledge base, semantic classes, knowledge projection, possibilistic supervised classification, possibilistic clustering.

**Abstract:** In this work, we propose a possibilistic geometric registration system that merges the semantic knowledge and the gray level knowledge of the images to be registered. The existing geometric registration methods are based on an analysis of the knowledge at the level of the sensors during the detection of the primitives as well as during the matching. The evaluation of the results of these geometric registration methods has limits in terms of the perfection of the precision caused by the large number of outliers. The main idea of our proposed approach is to transform the two images to be registered into a set of projections from the original images (source and target). This set is composed of images called "possibility maps", each map of which has a single content and presents a possibilistic distribution of a semantic class of the two original images. The proposed geometric registration system based on the possibility theory presents two contexts: a supervised context and an unsupervised context. For the first case, we propose a supervised classification method based on the theory of possibilities using learning models. For the unsupervised context, we propose a possibilistic clustering method using the FCM-multicentroid method. The two proposed methods provide as a result the sets of semantic classes of the two images to be registered. We then create the knowledge bases for the proposed possibilistic registration system. We have improved the quality of the existing geometric registration in terms of precision perfection, reduction in the number of false landmarks and optimization of time complexity.