

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement supérieur et de la recherche scientifique
Ecole Nationale Polytechnique.



DEPARTEMENT D'ELECTRONIQUE

THESE DE DOCTORAT
EN ELECTRONIQUE

présentée par

NACEREDDINE Nafaâ

Ingénieur d'Etat en Automatique (ENP)
Magister en Automatique (UMBB)

**Segmentation d'images par Approches Statistiques
et Recherche d'images par le Contenu. Application
aux images radiographiques de soudures**

soutenue publiquement le 6 juillet 2011 devant le jury composé de :

<i>Président :</i>	D. Berkani	Professeur	(ENP)
<i>Rapporteurs :</i>	L. Hamami	Professeur	(ENP)
	D. Ziou	Professeur	(U. Sherbrooke, Canada)
<i>Examineurs :</i>	A. Guessoum	Professeur	(USDB)
	Y. Chibani	Professeur	(USTHB)
	F. Hachouf	Maitre de Conférences A	(UMC)
<i>Invitée :</i>	N. Benblidia	Maitre de Conférences A	(USDB)

*A mes parents,
A ma femme,
A ma sœur et frères
A mon petit neveu Rami et
mes autres neveux et nièces*

Remerciements

Ce travail a été effectué sous la direction de Mme Hamami et Mr. Ziou à qui je tiens à exprimer ma reconnaissance pour leur disponibilité et pour la confiance dont ils ont fait preuve à mon égard durant tout le temps que m'a exigé ce travail.

Mes vifs remerciements vont aussi à Mr. Berkani qui a accepté de présider le jury de soutenance ainsi qu'à Mr. Guessoum, Mr. Chibani et Mme Hachouf qui ont accepté de participer en qualité d'examineurs dans ce jury. Aussi, je remercie Mme Benblidia d'avoir accepté notre invitation pour participer au jury.

Je ne peux manquer de remercier Mr Tabbone, professeur à l'université de Nancy 2, pour m'avoir accueilli au sein de son équipe au niveau du LORIA. Les membres des équipes QGAR du LORIA et RF-DISI du Centre de Recherche en Soudage et Contrôle trouveront ici mes remerciements pour l'ambiance amicale qu'ils ont su créer et les idées fructueuses que nous nous sommes échangés.

ملخص

الجزء الأول من هذا العمل يصف ثلاثة طرق لتجزئة الصورة من أجل كشف عيوب التلحيم في الصورة الإشعاعية. لهذا الهدف، اقترحنا أولاً، نموذج احتمالي للحد المتحرك مبني على المنطقة أين قمنا أيضاً بتحسين النموذج الأولي باستعمال عمليات التفارقة و المزج. بينما في الطريقة الثانية، قمنا بتقييم موضوعي لبعض طرق التجزئة على مستويين أين تبين لنا أن الطرق المحلية هي الأكثر نجاعة بالنسبة لصورنا. لاحظنا أيضاً نجاعة نموذج مزيج لقوانين غوس العامة في استخراج المناطق: عيب التلحيم، مفصل التلحيم و معدن الأساس. في النصف الثاني من هذا العمل، استعملنا نظام البحث عن الصورة بالمحتوى على بنك صور عيوب التلحيم أين اقترحنا واصف جديد قائم على المزج بين الواصف الهندسي و واصف فوريي العام و أين لاحظنا تحسين في نسب الاسترجاع مقارنة بالواصفين المذكورين أعلاه، كل واحد مستعمل على حدا

مفاتيح: التصوير الإشعاعي، عيب التلحيم، تجزئة الصورة، الحد المتحرك، نموذج المزيج، واصف الشكل، البحث عن الصورة بالمحتوى

RESUME

La première partie de ce travail décrit trois méthodes de segmentation d'images pour la détection des défauts de soudures dans les radiogrammes. Un modèle probabiliste de contour actif basé région est proposé. La modification du modèle initial en utilisant des opérations de séparation/fusion selon une métrique du contour améliore les résultats de la segmentation. Une évaluation objective de quelques méthodes de seuillage basées sur les approches globale et locale pour la détection des défauts est menée et discutée où les méthodes locales sont les plus efficaces. L'efficacité du modèle de mélange de gaussiennes généralisées est aussi observée dans l'extraction des régions du défaut, du cordon de soudure et du métal de base. Dans la deuxième partie du travail, l'approche de recherche d'image avec retour de pertinence est utilisée pour la base des défauts où un nouveau descripteur issu de la fusion des descripteurs géométriques de forme et des descripteurs de Fourier génériques a amélioré les taux de récupération.

Mots clés: Radiographie, défaut de soudure, segmentation d'images, contour actif basé région, seuillage, modèle de mélange, descripteur de forme, recherche d'image par le contenu

ABSTRACT

The first part of this work describes three methods of image segmentation to detect the weld defects in radiograms. A probabilistic model of a region-based snake is proposed. The modification of the initial model by using split and merge operation according to a contour metric improves the segmentation results. An objective evaluation of some thresholding methods based on global and local approaches for defect detection is carried out and discussed, where the local methods are most effective. The efficiency of generalized Gaussian mixture model is also observed in the extraction of defect, welding and base metal regions. In the second part of the work, content-based image retrieval with relevance feedback is used for the weld defect database where a new descriptor derived from merging of geometric descriptor and generic Fourier descriptor has improved the retrieval scores.

Key words: Radiography, weld defect, image segmentation, snake based region, thresholding, mixture model, shape descriptor, content-based image retrieval.

Sommaire

Introduction générale	1
------------------------------------	---

Chapitre 1 – Contrôle de soudure par radiographie et système de vision par ordinateur

I.1 Contrôle non destructif par radiographie	5
I.1.1 Aperçu sur le soudage, les défauts de soudures et le contrôle non destructif ...	5
I.1.2 Principe de la radiographie	7
I.1.3 Atténuation des rayons X et gamma	9
I.1.4 Application de la radiographie à l'examen des soudures	10
I.1.5 Mode opératoire de la radiographie par rayons X ou gamma	10
I.1.6 Considérations liées à la qualité de l'image radiographique	11
I.1.6.1 Contraste radiographique	11
I.1.6.2 Définition radiographique	11
I.1.7 Interprétation des radiographies de soudures	12
I.2 Système de vision par ordinateur dédié à la radiographie	14
I.2.1 Introduction	14
I.2.2 Schéma général du système de vision par ordinateur	14
I.2.3 Numérisation des images radiographiques	16
I.2.4 Prétraitement	17
I.2.4.1 Sélection interactive de la région d'intérêt	17
I.2.4.2 Modèle et réduction du bruit	18
I.2.4.3 Rehaussement du contraste	18
I.2.5 Segmentation, extraction de caractéristiques et interprétation	18
I.3 Conclusion	19

PREMIERE PARTIE – Segmentation d'images radiographiques par approches statistiques

Chapitre 2 – Segmentation d'images par un modèle déformable probabiliste

II.1 Introduction	23
II.2 Contours actifs basés contour	24
II.2.1 Modèles déformables paramétriques	24
II.2.1.1 Contour actif classique	24
II.2.1.2 Forces de pression	26
II.2.1.3 Flot de vecteur gradient	26
II.2.2 Modèles déformables géométriques/géodésiques	27
II.2.2.1 Méthode des ensembles de niveaux	27
II.2.2.2 Modèle déformable géométrique/géodésique	30

II.3 Contours actifs basés région	32
II.3.1 Approche basée région par le formalisme de Jehan-besson et al.	33
II.3.2 Approche variationnelle avec calcul de l'équation aux dérivées partielles . . .	35
II.3.2.1 En transformant les intégrales de domaines en intégrales de contour . . .	35
II.3.2.2 En utilisant les ensembles de niveaux	37
II.3.3 Approche variationnelle sans calcul de l'équation aux dérivées partielles . . .	35
II.4 Implémentation des contours actifs et représentation par B-splines cubiques	39
II.5 Evolution du contour déformable et l'approche glouton	42
II.6 Discussions	44
II.7 Approche statistique de segmentation par contours actifs	44
II.7.1 Point de vue énergétique et rôle de la paramétrisation	44
II.7.2 Point de vue Bayésien	45
II.7.3 Principaux modèles d'images	46
II.7.4 Approche Bayésienne pour l'estimation du contour	47
II.7.4.1 Contour discrétisé	47
II.7.4.2 Modèle d'observation d'images	48
II.7.4.3 Reparamétrisation de la B-spline par opération de division/fusion	50
II.8 Résultats expérimentaux	51
II.9 Conclusion	58

Chapitre 3 – Méthodes de seuillage d'images et post-traitement

III.1 Introduction	59
III.2 Seuillage basé sur l'histogramme 1-D	60
III.2.1 Définitions	60
III.2.2 Méthode de variance d'Otsu	62
III.2.3 Algorithme de minimisation d'erreur de Kittler et al.	63
III.2.4 Méthode de seuillage de Kapur basé sur l'entropie	65
III.2.4.1 Mesure de l'information	65
III.2.4.2 Entropie et seuillage	66
III.2.5 Méthode de seuillage par préservation des moments de Tsai	68
III.3 Seuillage basé sur l'histogramme 2-D	70
III.3.1 Matrice de cooccurrence et quadrants	70
III.3.2 Entropies locale et jointe	72
III.3.3 Entropie relative	72
III.4 Seuillage localement adaptatif	73
III.4.1 Méthode de Niblack	73
III.4.2 Méthode de Sauvola	74
III.5 Critère de mesure de la performance du seuillage	75
III.5.1 Erreur de classification	75
III.5.2 Non uniformité de région	75
III.5.3 Erreur relative de la région d'objet	76
III.5.4 Critère basé sur la forme de la région	76
III.5.5 Combinaison des mesures	77

III.6 Morphologie mathématique et post-traitement	78
III.7 Résultats expérimentaux	80
III.8 Conclusion	83

Chapitre 4 – Segmentation d’images par modèle de mélange de gaussiennes généralisées

IV.1 Introduction	84
IV.2 Modèle de mélange et l’algorithme EM	85
IV.3 GGMM pour la segmentation	86
IV.4 Génération de l’image segmentée	88
IV.5 Résultats expérimentaux	89
IV.6 Conclusion	90

DEUXIEME PARTIE – Indexation et recherche d’images par le contenu

Chapitre 5 – Indexation par extraction des caractéristiques de forme

V.1 Introduction	95
V.2 Descripteur géométrique de forme	96
V.2.1 Paramètres géométriques de base	96
V.2.2 Descripteur géométrique de forme (GEO)	97
V.2.3 Relation entre GEO et les types des défauts	99
V.2.4 Normalisation du descripteur géométrique de forme	100
V.2.5 Un exemple d’implémentation de GEO	101
V.3 Descripteurs de Fourier génériques	102
V.3.1 Transformée de Fourier polaire	102
V.3.2 Calcul des descripteurs de Fourier génériques	105
V.4 Calcul de descripteurs sur quelques images de défauts	107
V.5 Conclusion	109

Chapitre 6 – Recherche d’images et retour de pertinence

VI.1 Retour de pertinence : principe et état de l’art	110
VI.2 Le modèle MinReader et le modèle de Rui	112
VI.2.1 Solution optimale pour \vec{q}_i	113
VI.2.2 Solution optimale pour W_i	113
VI.2.3 Solution optimale pour u_i	115
VI.2.4 Solutions optimales pour MindReader	116
VI.2.5 Considérations pratiques	116
VI.3 Méthodologie expérimentale	117
VI.4 Un nouveau descripteur et évaluation du système de recherche	118
VI.5 Conclusion	124

Conclusion générale et perspectives	125
--	------------

Références bibliographiques	127
--	------------

Introduction générale

Actuellement, toute installation industrielle moderne ne peut être réalisée sans le soudage, qui offre des avantages incontestables aux assemblages soudés tels que : la légèreté, la tenue aux sollicitations de service, la précision d'exécution et l'esthétique [1]. Néanmoins, l'opération de soudage n'est pas toujours parfaite car les soudures réalisées peuvent présenter différents types de défauts, souvent dus aux processus de fabrications, aux contraintes d'effort, à la fatigue, aux changements environnementaux, au mauvais choix de la procédure de soudage, etc. C'est pourquoi, l'opération de contrôle de soudure devient nécessaire.

On entend par le contrôle non destructif (CND) tout examen de pièces ou d'assemblages utilisant des méthodes, qui n'altèrent pas leur structure, permettant ainsi leur utilisation ultérieure [2]. Une des techniques utilisées dans le CND est la radiographie qui est largement utilisée dans l'inspection de plusieurs types d'ouvrages soudés tels que les pipe-lines, les chaudières, les enceintes à pression, etc. Dans cette technique, on utilise les rayonnements X ou gamma où l'intensité de la radiation transmise à travers le joint soudé à examiner peut être détectée sur un film radiographique par le phénomène d'absorption différentielle. Les clichés obtenus par radiographie sont examinés par des experts radiographes, dont le rôle est de détecter, identifier et quantifier des défauts éventuels et de les accepter ou les rejeter en se référant aux normes et codes régissant le contrôle par radiographie (CR).

Ce travail est rendu particulièrement sensible en raison de la faible dimension de certains défauts (une fissure peut avoir une épaisseur inférieure à 200 μm), du mauvais contraste et de la nature bruitée du film radiographique. Ajoutant à cela des considérations subjectives liées, par exemple, à l'aptitude et l'expérience de l'interpréteur. L'expert travaille donc souvent dans des limites du système visuel et c'est pourquoi, l'interprétation de la qualité de la soudure peut, d'une manière non négligeable, devenir subjective, fastidieuse, et parfois inconsistante, pouvant ainsi compromettre les performances du contrôle [3].

Il y a donc un besoin d'introduire des techniques d'analyse d'images numériques dans ce domaine, où l'information visuelle fournie par l'image d'un film d'un joint soudé est très complexe, compte tenu des raisons citées plus haut.

Sur le volet scientifique, l'objectif de la thèse consiste dans l'utilisation de l'approche statistique d'analyse d'images, qui concernent habituellement des domaines tels que la télédétection, l'imagerie médicale, l'analyse des documents et la robotique, dans le domaine du contrôle non destructif des joints soudés par radiographie.

Par ailleurs, sur le volet professionnel, le but essentiel d'une partie du travail proposé est de familiariser l'interpréteur à l'utilisation de l'outil informatique à travers l'analyse et la recherche d'images dans le contrôle par radiographie, ce qui lui permettra de confronter les résultats obtenus par l'interprétation humaine à ceux obtenus par ordinateur. Cet outil pourrait être utilisé par le personnel de contrôle sur site à l'intérieur de laboratoires mobiles.

Quant à l'aspect technologique, l'avantage que confère les techniques de la vision par ordinateur est qu'elles permettent à l'interprétation des films radiographiques d'être automatisée, diminuant l'intervention de l'opérateur humain, rendant ainsi le système d'inspection plus fiable, reproductible et plus rapide [4].

Au point de vue économique, le système d'aide à la décision pour l'expertise de soudures développé dans ce travail apporte un outil performant et moderne dans la fabrication et le suivi des installations industrielles, où une interprétation et correction rapide des défauts et des problèmes qui leur sont liés ont comme conséquence la diminution des coûts de contrôle.

La connaissance parfaite de la géométrie des défauts de soudure est une étape indispensable pour apprécier la qualité de la soudure. La segmentation d'images constitue un des problèmes les plus significatifs dans la recherche d'image par le contenu et dans la reconnaissance des formes, parce que le résultat obtenu à l'issue de cette étape influe sur l'étape d'extraction de caractéristiques et par conséquent, conditionne fortement la qualité finale de l'interprétation. Malgré que les techniques de segmentation d'images ont fait l'objet d'un nombre considérable d'articles et d'ouvrages scientifiques dans la littérature [5], le nombre de celles qui sont appliquées au domaine du contrôle de soudures par radiographie [6-22] reste réduit en le comparant aux autres domaines tels que l'imagerie médicale, la télédétection, etc.

La difficulté à segmenter ce type d'images est dû à la complexité structurelle des images radiographiques et du contraste souvent insuffisant pour extraire la région d'intérêt, sans aucune connaissance *a priori* sur sa forme et sa localisation.

Généralement, les films de radiographie sont très sombres, leur densité est assez grande. Après numérisation, les principales caractéristiques de nos images sont un faible contraste entre le fond de l'image et les défauts de soudures qui possèdent des contours flous et peu marqués, une forte granularité due à la numérisation et aux types des films utilisés en radiographie industrielle et une présence d'un gradient de fond de l'image, caractérisant la variation d'épaisseur de la pièce contrôlée.

Après la sélection de la région d'intérêt (ang. *Region Of Interest* (ROI)), si nécessaire, qui est la région où la présence d'imperfections est suspectée, une étape de prétraitement peut être appliquée consistant en l'amélioration de contraste et l'élimination du bruit [23] dont le but est d'améliorer la visibilité de l'image d'entrée. Ceci permet à l'étape de détection de défaut de mieux localiser et représenter chaque défaut dans l'image. Les films radiographiques que nous avons numérisés ont été extraits en majorité de la base des radiogrammes étalons de l'Institut International de Soudure (IIS). Quelques centaines de régions d'intérêt représentant quatre classes de défauts de soudures (fissure, manque de pénétration, soufflure et inclusion de solide) sont extraites avec l'aide d'experts en radiographie.

Dans cette thèse, trois approches de segmentation seront proposées. La première approche sera consacrée au contour actif basé région utilisant un nouveau schéma de reparamétrisation de la B-spline en vue de détecter le défaut dans la ROI.

La deuxième approche de segmentation utilisera le seuillage et ce, pour extraire le défaut de la ROI. Après seuillage, un post-traitement basé sur la morphologie mathématique peut être appliqué dans le but d'extraire une seule région connexe représentant le défaut [24]. Quant à la dernière approche, elle sera dédiée à la segmentation en plusieurs régions basée sur une classification statistique des pixels utilisant les modèles de mélange dans le but d'extraire de l'image totale du radiogramme les régions du défaut, du cordon de soudure et du métal de base.

Dans cette thèse, il est à noter que seuls les résultats issus du seuillage seront exploités dans les étapes ultérieures à la segmentation. Les résultats issus de la segmentation par les modèles

déformables et les modèles de mélanges de lois statistiques pourront être exploités dans des travaux futurs dans le cadre de perspectives pour cette thèse.

Après la détection ou l'extraction du défaut, le problème est alors d'interpréter sa forme. Il est donc question de déterminer des descripteurs efficaces qui permettent de caractériser efficacement ces régions de défauts pour qu'elles deviennent des éléments de classe facilement identifiables. Cette étape consiste en l'indexation visuelle de la base des défauts extraits, c'est-à-dire la représentation des images de défauts sur la base de leurs caractéristiques de couleur, de forme ou de texture. Du moment où nos images sont issues d'un seuillage, seuls les caractéristiques ou descripteurs de formes seront d'un intérêt pour l'indexation.

La principale qualité d'un descripteur de forme est grande capacité de discrimination [25]. Il est aussi évident qu'un descripteur fiable doit être d'abord invariant aux transformations géométriques usuelles telles que la translation, la rotation et le changement d'échelle car en radiographie industrielle, un défaut de soudure s'il existe, doit être identifié comme tel en dépit de sa position, son orientation ou sa taille [26].

L'intérêt de l'utilisation d'un descripteur basé sur des mesures de formes (compacité, rectangularité, élongation, etc.) est qu'ils sont liés par une relation directe aux types de défauts de soudures cités plus hauts. Zhang et Lu [27] ont proposé le descripteur de Fourier générique (ang. *Generic Fourier Descriptor* (GFD)), connu pour son grand pouvoir discriminant, particulièrement pour les formes pleines.

Plusieurs travaux ont été consacrés à la classification des défauts de soudures en radiographie utilisant diverses approches (réseaux de neurones [9,26,28-31], machines à vecteurs de support [32], logique floue [33,34], classification linéaire [35], système expert [34,36], algorithme Espérance Maximisation (ang. *Expectation Maximization* (EM)) [37], etc.). Cependant, tous ces classifieurs ont comme objectif de diviser la totalité de la base en classes dont chacune correspond à un certain type de défaut ; ce qui nécessite un temps d'exécution considérable surtout, dans le cas de grandes bases d'images. En effet, la radiographie industrielle peut produire une quantité énorme d'images. Il serait donc opportun d'utiliser la recherche d'images par le contenu (ang. *Content-based image retrieval* (CBIR)) avec retour de pertinence (ang. *Relevance feedback* (RF)) [39-48] dans ce domaine où le sujet n'a presque pas été traité [38]. En outre, dans le CND, nous nous intéressons parfois à la recherche d'un certain type de défaut qui peut être nocif à tel ou tel composant industriel. Un CBIR est un processus pour trouver des images semblables dans le contenu visuel à une requête donnée à partir d'une base de données d'images. Il est souvent réalisé par une comparaison des caractéristiques visuelles de bas-niveau telles que la couleur, la forme ou la texture, extraites à partir des images elles-mêmes [43]. Bien qu'il existe un grand besoin de l'utilisateur pour une meilleure gestion des données d'images dans divers, il y a une disparité importante entre les capacités des techniques de CBIR et les besoins des utilisateurs [47]. Ce problème s'appelle le fossé sémantique, un terme employé pour exprimer l'anomalie entre les descripteurs de bas niveau qui peuvent être aisément extraits des images et les descriptions qui sont significatives pour les utilisateurs. L'amélioration itérative du procédé de recherche par le retour de pertinence est l'un de mécanismes pour réduire l'espace sémantique dans les technologies de CBIR en incluant l'utilisateur dans la boucle de recherche [47].

Le manuscrit de la thèse est organisé de la manière suivante :

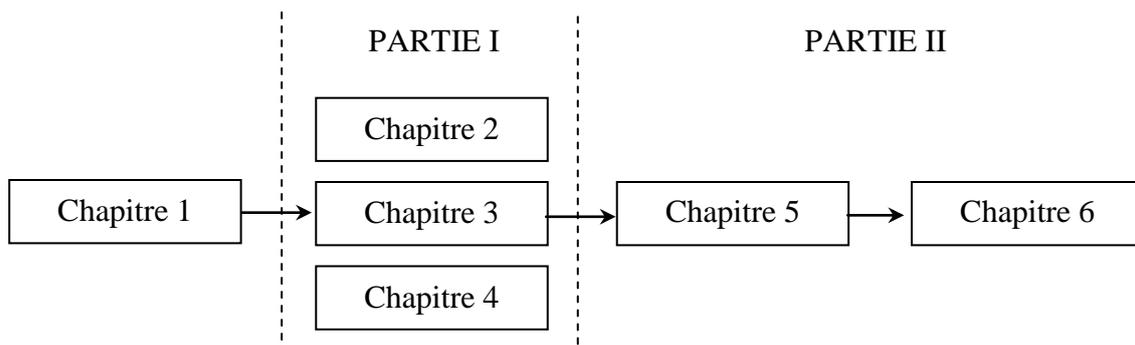
La thèse sera composée de six (6) chapitres et deux (2) parties. Dans le chapitre 1, nous donnerons un aperçu sur le soudage, les défauts de soudure, le contrôle non destructif par radiographie et le système de vision dédié à la détection et l'identification des défauts.

La partie I qui traitera de la détection des défauts par les méthodes statistiques de segmentation d'images sera composée de 3 chapitres :

Le chapitre 2 sera consacré à la méthode des contours actifs utilisant l'approche probabiliste. Dans ce chapitre, après avoir donné un état de l'art des méthodes de contours actifs existantes, une nouvelle variante d'un contour actif probabiliste basé sur un algorithme de type de division/fusion sera proposée. Dans le chapitre 3, neuf méthodes de seuillage basées sur les statistiques des histogrammes 1D, 2D et le voisinage du pixel seront développées. Une évaluation de ces méthodes de seuillage à l'aide de critères supervisés et non supervisés sera conduite sur un échantillon d'images de défauts. Les meilleures méthodes de seuillage retenues seront suivies d'un post-traitement pour que l'image binaire du défaut soit représentée par une seule région connexe. Les images des défauts qui seront utilisées dans les étapes ultérieures seront issues de ce chapitre. Le dernier chapitre (chapitre 4) de cette partie exposera la segmentation d'images basée sur les modèles de mélanges de lois de probabilités. Dans cette partie du manuscrit, nous avons proposé la loi gaussienne généralisée, connue pour sa flexibilité, dans le modèle de mélange, et dont les résultats de segmentation sont comparés avec le modèle utilisant la loi normale simple. En général, cette méthode de segmentation permettra de diviser l'image de radiographie de soudure en ses composantes principales à savoir : le défaut, le cordon de soudure et le métal de base.

La partie II de la thèse s'occupera de l'identification du défaut. A cet effet, deux chapitres lui seront dédiés. Le chapitre 5 traitera de la description du défaut. Deux descripteurs de formes seront utilisés, l'un contient quelques mesures géométriques et les deux premiers moments invariants et l'autre n'est autre que le descripteur de Fourier générique. Enfin, le dernier chapitre de cette partie et à la fois de cette thèse montrera la faisabilité de l'approche recherche d'image dans le domaine du CND par radiographie où deux systèmes de recherche d'images avec retour de pertinence (MindReader [39] et le modèle de Rui [42]), utilisant les descripteurs cités plus haut, seront appliqués sur la base des défauts de soudures. En outre, un nouveau descripteur issu de la fusion des deux premiers sera testé par MindReader en vue l'amélioration des résultats de recherche.

On peut résumer le plan de la thèse par le diagramme en blocs suivant :



Chapitre 1

Contrôle de soudure par radiographie et système de vision par ordinateur

I.1 Contrôle non destructif par radiographie

I.1.1 Aperçu sur le soudage, les défauts de soudures et le contrôle non destructif

La plupart des réalisations industrielles modernes ne peuvent se passer du soudage qui offre des avantages incontestables aux assemblages soudés tels que : légèreté, tenue aux sollicitations de service, précision d'exécution et esthétique [1]. Les soudures sont largement utilisées dans beaucoup de secteurs tels que la pétrochimie, l'aéronaval, la construction automobile, les réacteurs d'énergie nucléaire et l'électronique. Le soudage est un procédé qui consiste à assurer la continuité métallique entre deux éléments à assembler, contrairement aux autres techniques d'assemblage (boulonnage, rivetage, etc.). Le soudage permet d'assembler la quasi-totalité des métaux, dans pratiquement toutes les positions et dans tous les milieux, tout en assurant une bonne continuité de la matière, une bonne transition des efforts, une bonne résistance et une parfaite étanchéité. Les métaux et alliages s'y prêtent particulièrement bien, en raison de leur pouvoir de diffusion élevé. Néanmoins, l'opération de soudage ne peut être toujours parfaite et peut produire des discontinuités et des imperfections dans les structures soudées. Ces discontinuités sont en général inhérentes aux procédés de soudage. En fait, ils dépendent de plusieurs facteurs : mauvaises exécutions (surcharge, pression, durée d'application, etc.), qualité du métal de base et/ou du produit d'apport, propreté des régions à souder et choix du procédé lui-même. Une classification détaillée des défauts de soudures est décrite dans [49]. Quelques types de défauts sont récapitulés dans Fig. I.1.

Par conséquent, l'inspection des composants de soudage est une opération qui s'impose. On utilise le terme contrôle non destructif (CND) pour désigner les méthodes principales d'inspection qui permettent l'évaluation des soudures et des matériaux de soudage sans affecter leur utilité. Dans le CND, une discontinuité est établie comme étant un défaut par une spécification qui fixe le type et les dimensions des discontinuités qui sont inacceptables [50].

Chacune des méthodes de CND est spécifique et est destinée à mesurer certaines propriétés ou à mettre en évidence certains types de défauts. Elles doivent donc être choisies en fonction du matériau examiné, l'anomalie que l'on désire détecter, les avantages et les limitations de la méthode d'inspection, les normes d'acceptation et le coût.

Les méthodes de contrôle non destructif utilisées couramment sont :

- **Le contrôle visuel**, qui ne doit pas être oublié, est généralement pratiqué par le soudeur lui-même : linéarité et régularité du cordon de soudure, absence de surépaisseur ou de criques, de caniveaux (manque de fusion du métal sur les bords de la soudure), bonne pénétration du métal d'apport, etc.

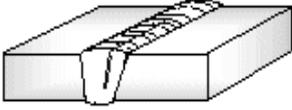
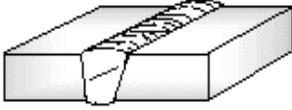
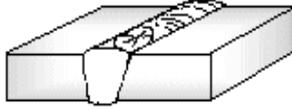
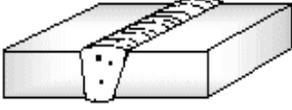
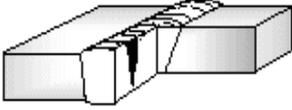
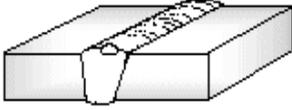
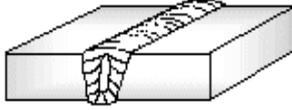
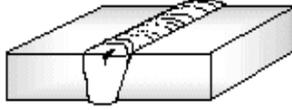
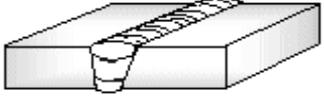
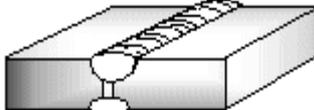
GROUPE N° 1 – FISSURES			
			
FISSURE LONGITUDINALE	FISSURE TRANSVERSALE	FISSURES RAYONNANTES	FISSURES DE CRATÈRE
GROUPE N° 2 – CAVITÉS OU POROSITES			
			
SOUFFLURE SPHEROIDALE	SOUFFLURES ALLIGNEES	NID DE SOUFFLURES	SOUFFLURES ALLONGÉES
			
SOUFFLURE VERMICULAIRE	PIQÛRE	RETASSURE INTERDENTRITIQUE	RETASSURE DE CRATÈRE
GROUPE N° 3 - INCLUSIONS SOLIDES			
			
INCLUSION DE LAITIER	INCLUSION DE FLUX	INCLUSION D'OXYDE	INCLUSION MÉTALLIQUE
GROUPE N° 4 - MANQUE DE FUSION			
			
MANQUE DE FUSION DES BORDS OU COLLAGE		MANQUE DE FUSION ENTRE PASSES	
GROUPE N° 5 - MANQUE DE PÉNÉTRATION			
			
MANQUE DE PÉNÉTRATION		MANQUE D'INTERPÉNÉTRATION	

Fig. I.1 Quelques types de défauts de soudage

- **Le contrôle par ressuage** utilisable pour la recherche des défauts débouchant en surface de tous les métaux non poreux. Ce contrôle a besoin d'un liquide appelé « pénétrant » pour s'infiltrer dans la discontinuité et d'un révélateur, souvent une poudre fine pour attirer le pénétrant en dehors de la discontinuité, reproduisant sa forme et sa taille. Le pénétrant contient soit un traceur rouge visible en lumière naturelle, soit un traceur fluorescent pour examen en lumière ultraviolette.
- **Le contrôle par magnétoscopie** qui permet de déceler des défauts affleurant la surface mais il est uniquement utilisable pour des matériaux ferromagnétiques. Sous l'action d'un champ magnétique, les particules magnétiques en suspension dans un liquide s'accumulent à l'endroit des défauts.
- **Le contrôle par ultrasons** qui utilise des ondes élastiques à fréquence élevée, de l'ordre du Mégahertz, qui se propagent dans le milieu, grâce à la mise en vibration élastique, autour de leur position d'équilibre, des points matériels constituant le matériau.
Dans l'examen des soudures, on fait généralement appel aux ondes transversales qui vibrent perpendiculairement au sens de leur propagation. Le contrôle des soudures peut se faire, soit par transmission (deux palpeurs séparés : un émetteur et un récepteur), soit par réflexion ou par échos (un seul palpeur émetteur et récepteur).
- **Le contrôle d'étanchéité** qui permet de déceler les fuites dues à des défauts de dimensions microscopiques par mise sous pression ou en dépression du conteneur à contrôler au moyen d'un gaz (hexafluorure de soufre, hélium, ammoniac, etc.) ou d'un liquide.
- **Le contrôle par courant de Foucault** est largement utilisé pour détecter les défauts de surface. Cette méthode s'applique aux matériaux conducteurs d'électricité uniquement. Lorsqu'une bobine parcourue par un courant alternatif est approchée à la pièce, des courants de Foucault sont induits dans celle-ci par induction électromagnétique. L'amplitude des courants de Foucault induits dépend, entre autres, de la présence des discontinuités dans la pièce.
- **Le contrôle par radiographie** s'effectue principalement avec les rayons X ou les rayons gamma. Ces rayonnements ont la propriété de pénétrer la matière, d'être plus ou moins atténués selon la densité et l'épaisseur des matériaux traversés et de transporter une "image radiante" de ces derniers, qui peut être convertie en image visible sur un dispositif approprié : un film radiographique (radiographie industrielle) ou un écran fluorescent (radioscopie industrielle).
Les sections suivantes seront consacrées à cette dernière méthode. En effet, les images issues de cette technique feront l'objet d'analyse dans les prochains chapitres.

I.1.2 Principe de la radiographie

La radiographie est un procédé d'examen de matériaux qui utilise les rayonnements ionisants tels que les rayons X ou les rayons gamma. Ceci permet l'examen de l'intérieur des objets ou des assemblages qui sont opaques à la lumière. La radiographie est considérée comme une méthode de contrôle non destructif puisque les objets qui sont examinés ne sont pas altérés par l'essai et peuvent toujours être utilisés quand l'essai est accompli. En traversant le matériau,

une partie du rayonnement est absorbée ou transformée. La quantité d'absorption dépend de l'épaisseur et la densité du matériau et du nombre atomique de l'atténuateur ou écran. Un certain type de détecteurs tels que le film peut servir pour l'enregistrement des variations de l'intensité du rayonnement incident sous forme d'images. Voici donc, les trois bases essentielles dans la production d'une radiographie : une source de rayonnement des rayons X ou gamma, l'objet à examiner et une cassette contenant le film.

La Figure I.2 illustre les principaux éléments pour l'obtention d'un film radiographique. La source de rayonnement peut être un générateur de rayon X ou une capsule contenant le radio-isotope approprié tel que le Cobalt-60 ou l'Iridium-192. Certains rayonnements émis par la source traversent l'objet, certains sont absorbés par l'objet, alors que d'autres sont diffusés dans toutes les directions par l'objet. La quantité de rayonnement atteignant le film dans la cassette dépend d'un certain nombre de facteurs liés à la nature du matériau irradié et son épaisseur. Supposons que l'objet examiné soit une pièce en acier renfermant une porosité gazeuse. Il y a une réduction de l'épaisseur de l'acier à l'endroit de la porosité. Par conséquent, il y aura plus de rayonnement qui traversera l'endroit en question par rapport au reste de la pièce. Une tache foncée correspondant à la position projetée de la bulle apparaîtra sur le film après qu'il soit développé. Les régions les plus foncées sur la radiographie représentent les parties de l'objet les plus facilement pénétrées par le rayonnement, et vice versa.

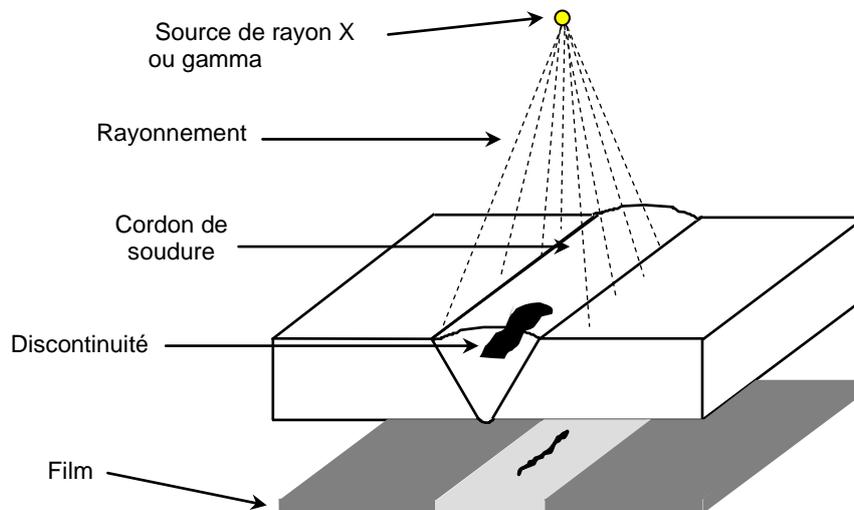


Fig. I.2 Schéma représentatif du principe de la radiographie

Les rayons X et les rayons gamma possèdent les propriétés principales suivantes [51]:

- a. Ce sont des radiations électromagnétiques invisibles.
- b. Ils peuvent pénétrer dans la matière.
- c. Ils sont absorbés par la matière de manière différentielle.
- d. Ils produisent des effets photochimiques sur des émulsions photographiques.

Les rayons X et les rayons gamma sont des ondes électromagnétiques de même nature physique. Ils ont les mêmes propriétés, mais ils n'ont pas la même source de production. Les rayons X sont générés par l'intermédiaire d'un appareillage électrique. Par contre, les rayons gamma proviennent de la désintégration des noyaux atomiques d'éléments radioactifs. L'énergie des rayons gamma n'est pas réglable ; elle dépend de la nature de la source radioactive. L'intensité n'est pas réglable non plus, car il n'est pas possible de modifier le taux de désintégration d'une matière radioactive. Tout comme les rayons X, les rayons gamma sont partiellement absorbés lorsqu'ils traversent un matériau, ce qui permet de les utiliser pour obtenir une image radiographique.

I.1.3 Atténuation des rayons X et gamma

L'utilisation des rayons X et gamma en radiographie repose sur l'absorption différentielle. En conséquence, il est important de comprendre comment les rayons X et gamma réagissent avec la matière. La Figure I.3 montre le dispositif utilisé pour mettre en évidence le phénomène d'absorption de rayons par les matériaux.

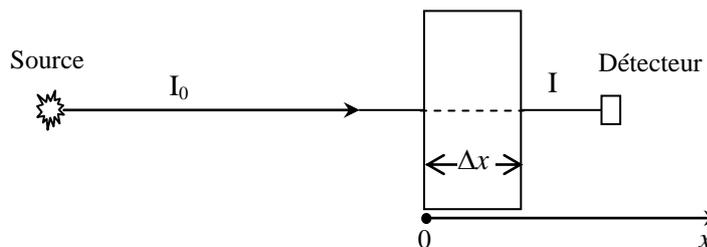


Fig. I.3 Dispositif expérimental pour étudier l'absorption

Un faisceau homogène des rayons X ou gamma d'intensité I_0 , traversant une épaisseur Δx d'un matériau, subit une diminution d'intensité ΔI qui est proportionnelle à l'intensité du faisceau incident et à l'épaisseur du corps absorbant, ce qui s'écrit sous la forme mathématique :

$$\Delta I = -\mu I \Delta x \quad (\text{I.1})$$

où μ est une constante de proportionnalité et où le signe moins est utilisé pour indiquer une diminution d'intensité. Cette équation peut être écrite sous la forme intégrée comme

$$I = I_0 \exp(-\mu x) \quad (\text{I.2})$$

où

I_0 : intensité de la radiation incidente

I : intensité de la radiation transmise

x : épaisseur du spécimen

μ : coefficient linéaire d'absorption pour le matériau

Cette expression est la loi fondamentale régissant l'absorption d'un faisceau homogène de rayons X ou de rayons gamma.

Dans le dispositif décrit dans la Figure I.3, si le détecteur est déplacé soit vers la droite, soit vers la gauche, un maximum de lecture est obtenu quand le détecteur est placé en position moyenne. En effet certains rayons X ou gamma émergent du corps absorbant suivant des directions différentes de celles suivant lesquelles ils sont entrés. Cette radiation est appelée radiation diffusée ou dispersée, et quand l'échantillon d'essai a une épaisseur appréciable, la radiation peut être dispersée plus d'une fois. Le détecteur reçoit la radiation dispersée aussi bien que la radiation principale, et il ne peut distinguer les deux. Le coefficient d'absorption mesuré est composé de deux parties, une absorption vraie et un coefficient de dispersion. L'absorption vraie est caractérisée par la disparition des quantas des rayons X et le transfert de l'énergie de ceux-ci aux électrons du matériau. La radiation dispersée est caractérisée par un changement de direction par rapport au faisceau principal. Elle consiste en une radiation modifiée et en une radiation non-modifiée. La radiation modifiée subit une variation d'énergie, tandis que la radiation non-modifiée ne subit aucun changement d'énergie.

Quatre processus d'interaction ont lieu quand des rayons X ou gamma traversent la matière dont la prépondérance dépend de l'énergie du rayonnement incident et du matériau irradié. Ces processus sont respectivement : la diffusion Rayleigh, l'effet photoélectrique, la dispersion Compton et la production d'une paire d'électrons [51].

I.1.4 Application de la radiographie à l'examen des soudures

L'application de la radiographie industrielle qui nous intéresse dans ce travail est le contrôle non destructif des joints soudés dont le but est de distinguer un défaut spécifique des autres défauts dans l'image du film radiographique. Le contrôle a pour but de mettre en évidence les caractéristiques et les dimensions du défaut, c'est à dire déterminer la qualité ou l'état d'un matériau avec l'intention d'accepter ou de rejeter ce dernier [52]. Du point de vue industriel, cela revient à déterminer si un matériau ou une pièce répondra d'une façon satisfaisante à la fonction qui lui sera demandée, permettant ainsi : l'augmentation de la productivité et des bénéfices, l'augmentation de la sécurité (éviter les accidents) et l'augmentation de la durée de vie des installations (éviter le mauvais fonctionnement des équipements).

I.1.5 Mode opératoire de la radiographie par rayons X ou gamma

Une source d'émission de rayonnement est donc placée d'un côté de la pièce à contrôler et un film radiographique est mis de l'autre côté.

Plusieurs paramètres vont intervenir dans la radiographie tels que le temps d'exposition de la pièce aux rayonnements afin d'obtenir une bonne image.

La nature de l'ouvrage à contrôler ainsi que la norme ou code de référence vont imposer et fixer certains paramètres, tels que la classe de films à utiliser, les dimensions de la source de rayonnement, le flou géométrique, la densité du film, le contraste, etc.

A partir de ces paramètres, le temps d'exposition est établi. La pièce est ainsi irradiée. Le film obtenu est développé et traité en chambre noire; une fois asséché, ce cliché est lu sur un négatoscope et les résultats de cette interprétation sont consignés sur un rapport de contrôle.

Toutefois, l'interprétation reste soumise aux recommandations du code ou la norme de référence qui définira l'acceptabilité ou le refus de la pièce examinée.

La définition et l'illustration des différents paramètres intervenants dans le mode opératoire d'une radiographie par rayons X ou gamma sont données dans Radiographie industrielle [53].

I.1.6 Considérations liées à la qualité de l'image radiographique

Le détecteur le plus souvent utilisé en radiographie industrielle est le film. La sensibilité élevée à la radiation ionisante fournit d'excellents détails et sensibilités aux changements de densité lors de la production des images des matériaux industriels. La qualité d'image est déterminée par une combinaison des variables : contraste et définition radiographiques. Plusieurs variables affectant le contraste et la définition radiographiques sont récapitulées ci-dessous :

I.1.6.1 Contraste radiographique

Le contraste est déterminé par les variables suivantes :

- Absorption différentielle dans le spécimen irradié
- Longueur d'onde du rayonnement primaire
- Diffusion ou rayonnement secondaire

Le contraste du film est déterminé par ce qui suit :

- Taille des grains ou le type du film.
- Composition chimique et concentration des produits de développement.
- Temps du développement.
- Température.
- Degré d'agitation mécanique.

Densité du film radiographique :

- Une densité plus élevée fournira un plus grand contraste.
- Les écrans de plomb dont les épaisseurs varient entre 0,1 et 0,4 mm réduiront l'effet des radiations diffusées à des niveaux d'énergie inférieur à 150 kV. En plus, ils émettront des électrons pour accroître l'exposition du film aux radiations ionisantes augmentant ainsi, la densité de la radiographie.
- Les écrans fluorescents ne fournissent aucun filtrage. Une fois exposés au rayonnement, ils émettent des rayons lumineux auxquels le film est sensible. Il en résulte une augmentation du contraste de l'image.

I.1.6.2 Définition radiographique

Les facteurs géométriques incluent ce qui suit :

- La taille de la tache focale, qui est le point d'origine du rayonnement, devrait être presque une source ponctuelle à la mesure du possible.

- La distance entre la source et le film, devrait être maintenue au minimum.
- Le spécimen et le film doivent être en contact étroit.
- Les changements brusques de l'épaisseur du spécimen peuvent causer une déformation sur le film.
- Le mouvement du spécimen pendant l'exposition produira une déformation sur la radiographie.

Granulation de film :

- La vitesse d'imprégnation du film édictera la définition de la radiographie.
- La longueur d'onde du rayonnement influencera la granulation apparente. Pendant que la longueur d'onde diminue et la pénétration augmente, la granulation apparente du film augmentera.
- Un temps de développement du film plus grand augmentera la granulation apparente de la radiographie.

Le contraste et la définition sont des paramètres fondamentaux qui déterminent la qualité du film radiographique. L'essentiel de la technique visant à obtenir une radiographie de qualité satisfaisante se résume dans l'optimisation de ces deux facteurs et dans de le contrôle de leur incidence sur la détectabilité des défauts présents dans un matériau [54].

I.1.7 Interprétation des radiographies de soudures

En plus de la production des radiographies de haute qualité, le radiographe doit également être habile dans l'interprétation radiographique. L'interprétation des radiographies a lieu dans trois étapes de base qui sont **(1)** détection, **(2)** interprétation et **(3)** évaluation. La capacité d'un individu de détecter des discontinuités en radiographie est affectée par sa capacité de percevoir avec une bonne résolution une forme spatiale dans une image et le niveau d'expérience pour identifier les différents traits descriptifs dans l'image. On énumère dans ce qui suit les discontinuités examinées par radiographie dans le cadre de cette thèse.

La porosité est le résultat de l'occlusion du gaz dans le métal lors de sa solidification. Les porosités peuvent prendre plusieurs formes sur une radiographie, mais apparaissent souvent comme des taches foncées ou des points ronds ou irréguliers. La porosité peut se produire seule, en groupe ou alignée. Toute porosité est un vide dans le métal. Elle a donc une densité radiographique plus grande que celle de son voisinage.

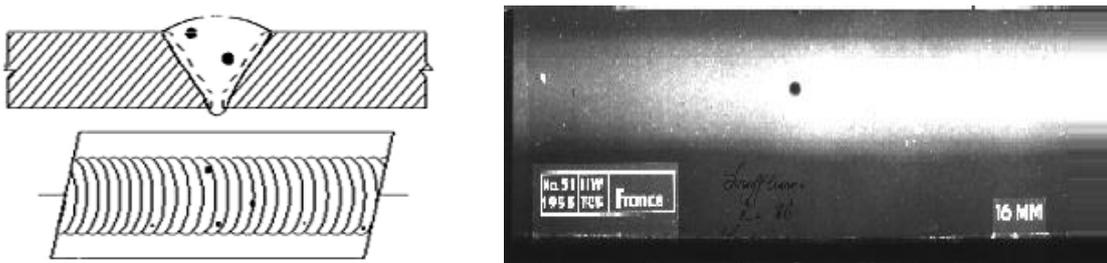


Fig. I.4 Porosité

Les inclusions de solide (exp. laitier, oxyde, etc.) sont des corps solides non métalliques enfermés dans le métal de la soudure ou entre ce dernier et le métal de base. Dans une radiographie, le noircissement et la forme asymétrique et biscornue dans la zone du joint soudé sont indicatifs des inclusions de laitier.

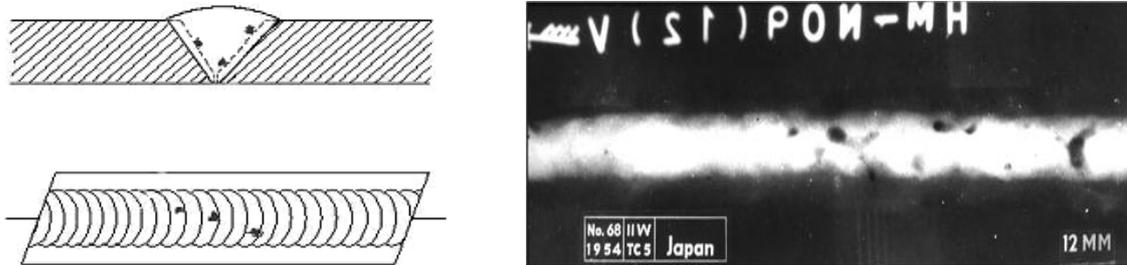


Fig. I.5 Inclusions de solide (laitier)

Le manque de pénétration se produit quand il y a un remplissage incomplet du fond de la rainure de la soudure avec le métal de soudage. Elle est l'une des discontinuités de soudage les plus répréhensibles. Le manque de pénétration produit une canalisation de contraintes où une fissure peut se propager. L'aspect sur une radiographie donne une zone foncée avec des bords bien définis et rectilignes et qui est centrée sur la racine du joint soudé.

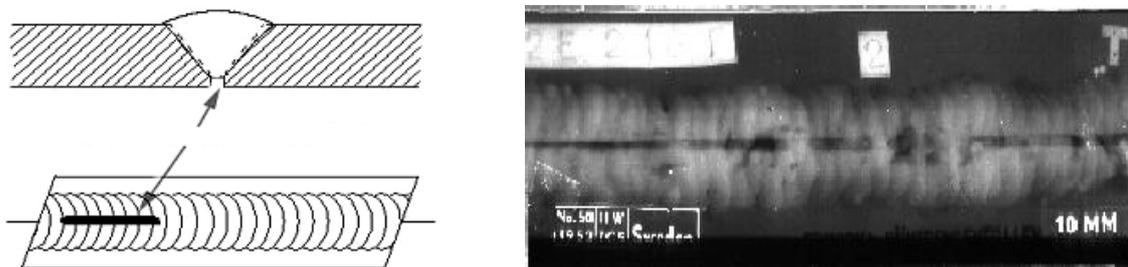


Fig. I.6 Manque de pénétration

La fissure qui peut être détectée dans une radiographie est seulement celle qui se propage dans une direction qui a produit une variation d'épaisseur, laquelle est parallèle au faisceau du rayonnement. Les fissures apparaissent comme des lignes irrégulières quelconques et souvent très fines.



Fig. I.7 Fissure

I.2 Système de vision par ordinateur dédié à la radiographie

I.2.1 Introduction

Avec le progrès qu'a connu la technologie de l'ordinateur, on assiste actuellement à l'émergence des techniques de traitement numérique des images qui sont appliqués dans divers domaines tels que l'imagerie spatiale et la recherche biomédicale.

Néanmoins, ces dernières années, ces techniques intéressent de plus en plus le domaine du contrôle non destructif par radiographie, où les images des films radiographiques peuvent être numérisées et leur être appliquées les techniques du traitement numérique des images et ce, dans le but d'améliorer leur visibilité et d'en extraire les paramètres pertinents pour effectuer une interprétation [55].

Plusieurs facteurs ont contribué au développement de la technologie du traitement d'image :

- La grande quantité d'informations supportée par une image digitale dans une forme compacte est facilement manipulable, le support d'implantation offert par l'ordinateur pour plusieurs techniques ne pouvant pas se traiter avec une technologie non digitale.
- Les performances atteintes par les systèmes d'acquisition d'images et la croissance des systèmes informatiques, la tendance vers les composants rapides et moins coûteux et la haute densité de stockage de l'information digitale. Les possibilités nettement accrues des systèmes vidéo ont permis le traitement, la manipulation et l'affichage de grands volumes de l'imagerie numérique.
- Les efforts mathématiques réalisés notamment dans le domaine du traitement numérique de signal ont permis la mise au point d'algorithmes de calcul rapide rendant possible de nombreuses opérations complexes sur les images.

Le traitement numérique des images recouvre l'ensemble des procédés d'amélioration et d'extraction d'informations qualitative des images numériques, selon les utilisateurs et les besoins requis, pour en donner, soit des nouvelles images ou bien des évaluations particulières. L'expert radiographe a pour rôle d'inspecter chaque film afin d'y détecter la présence d'éventuels défauts qu'il doit alors identifier et mesurer. Ce travail est rendu particulièrement délicat du fait de la faible dimension de certains défauts (une fissure peut avoir une épaisseur inférieure à $200 \mu m$), du manque de contraste et du caractère bruité de l'image du film.

L'expert travaille souvent aux limites du système visuel où la part de subjectivité dans les mécanismes de détection et de mesure des défauts n'est pas négligeable.

L'emploi des techniques de traitement numérique d'image et de reconnaissance de formes a pour but non seulement de détecter et d'identifier automatiquement les défauts mais aussi, d'une part, d'offrir une meilleure visualisation de l'information et d'autre part de formaliser les méthodes d'expertise radiographique afin de les rendre robustes et systématiques [52].

I.2.2 Schéma général du système de vision des radiogrammes

La division d'un système de vision par ordinateur des images en trois principaux domaines est la plus utilisée [56]. Ces domaines sont :

- a. Traitement bas-niveau,
- b. Traitement niveau intermédiaire
- c. Traitement haut-niveau.

Bien que ces subdivisions n'aient pas de frontières définitives, elles font promouvoir un fondement utile pour la catégorisation des divers processus qui sont des composantes inhérentes d'un système autonome de vision par ordinateur.

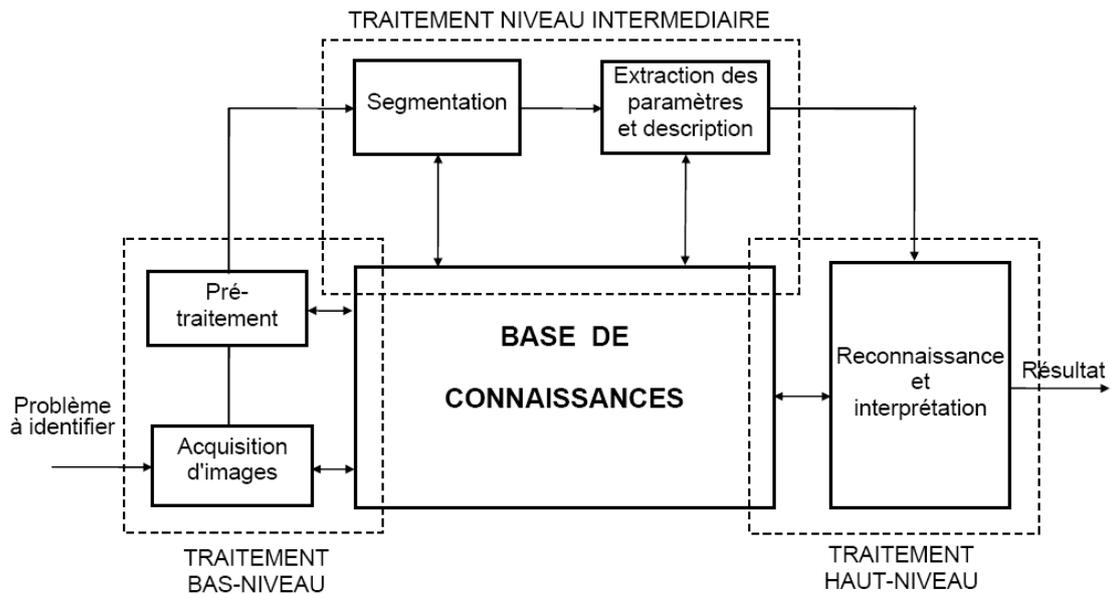


Fig. I.8 Description générale d'une chaîne de vision par ordinateur

Fig. I.8 illustre ces concepts avec un chevauchement des lignes en pointillés pour indiquer qu'il n'y a pas de limites précises entre les différents processus.

Par exemple, le seuillage peut être considéré comme un lissage (prétraitement) ou un outil de segmentation et ce, selon l'application.

Le traitement *bas-niveau* se sert des fonctions qui peuvent être considérées comme des réactions automatiques, ne demandant aucune intelligence de la part du système de vision. On considère l'acquisition et le prétraitement de l'image comme des fonctions de bas-niveau.

Le *niveau intermédiaire* de traitement présente la tâche d'extraction des caractéristiques dans une image issue d'un traitement bas-niveau. Comme l'illustre la figure ci-dessus, le traitement niveau intermédiaire renferme la segmentation et l'extraction des traits descriptifs. Certaines capacités pour un comportement intelligent sont conférées par des procédures de segmentation. Par exemple, la fermeture de contours dans les images segmentées implique des outils plus sophistiqués que pour l'accomplissement de cette tâche. Ce qui n'est pas le cas pour les traitements bas-niveau.

Enfin, le traitement *haut-niveau* implique la reconnaissance (dans notre application, il s'agit de la recherche d'images) et l'interprétation. Ces deux processus ont une forte ressemblance qui est généralement signifiée par le terme perception ou cognition intelligente. La majorité des techniques utilisées dans les traitements bas-niveau et niveau intermédiaire renferme un

ensemble de formulations théoriques bien définies. Cependant, les problèmes de vision haut-niveau concerne l'intégration d'information sémantique sur toute l'image à analyser (quel est le but poursuivi ? de quelles connaissances a-t-on besoin ? par exemple) en se servant à la fois d'une base de connaissances appropriées utilisant les techniques de l'intelligence artificielle et du niveau inférieur pour, éventuellement, lui demander des compléments d'informations. Cela implique l'existence d'une grande interaction entre ce niveau et le niveau intermédiaire [57]. Pour notre application, nous avons un système de vision par ordinateur dédié aux images des films radiographiques, comportant les parties suivantes :

- Numérisation du film : Acquisition
- Amélioration de la visibilité de l'image radiographique : Prétraitement
- Extraction de la zone du défaut : Segmentation et Post-traitement (si nécessaire).
- Indexation de la base des défauts : Extraction de caractéristiques.
- Identification des défauts : Classification / Recherche d'image par le contenu.

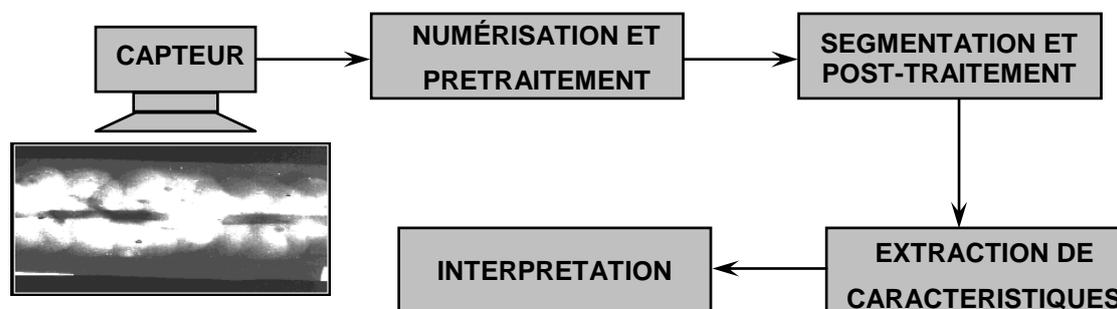


Fig. I.17 Schéma du système de vision dédié aux films radiographiques

I.2.3 La numérisation des images radiographiques

La numérisation des films après leur exposition aux radiations constitue la première étape pour un traitement ultérieur. Elle consiste en la conversion des signaux analogiques en données numériques positives comprises entre 0 et 255 (0 : noir, 255 : blanc et entre ces deux valeurs se situent les différents niveaux de gris). Généralement, les films de radiographie sont très sombres, leur densité est assez grande, donc un scanner ordinaire ne peut donner un éclairage suffisant à travers un radiogramme. Bien sûr, des scanners spécialisés appropriés à prendre des copies de haute qualité des radiogrammes existent, mais ils sont coûteux. Pour nos images de radiographie, nous avons utilisé un scanner AGFA Arcus II, (800 dpi, 256 niveaux de gris). Après numérisation, les principales caractéristiques de nos images sont :

- a. Un faible contraste entre le fond de l'image et les défauts de soudures. Ces derniers possèdent des contours flous et peu marqués.
- b. Une forte granularité due à la numérisation et aux types des films utilisés en radiographie industrielle.
- c. La présence d'un gradient du fond de l'image, caractérisant la variation d'épaisseur de la pièce contrôlée.

I.2.4 Prétraitement

Le prétraitement est un terme qui sert à désigner les opérations sur des images au plus bas niveau de traitement, l'entrée et la sortie sont toutes les deux des images en niveau de gris.

Le but du prétraitement est l'amélioration de la visibilité des images en supprimant les déformations non désirées ou en augmentant les aspects de l'image utiles pour les traitements ultérieurs. Pour les raisons évoquées dans la section précédente, il devient difficile, sinon aléatoire de déceler, lors de la visualisation du radiogramme, la présence des petits défauts et déterminer leurs grandeurs avec exactitude. C'est pourquoi, il est souvent nécessaire de commencer par l'étape du prétraitement dans le but de réduire ou éliminer le bruit et améliorer le contraste. Cette marche à suivre nous permet d'obtenir une image qui faciliterait plus tard l'identification des défauts de soudure pouvant être présents dans le joint soudé. Néanmoins, la première tâche dans le prétraitement de l'image est la sélection de la région où le défaut de soudure est susceptible d'être trouvé, et qui peut être faite d'une manière interactive après la visualisation du film radiographique. Cette région est appelée région d'intérêt.

I.2.4.1 Sélection interactive de la région d'intérêt

En utilisant une évaluation interactive de la qualité du joint soudé, la première tâche de l'interpréteur en radiographie est de marquer ces parties de l'image, où ils suspectent la présence d'imperfections. A cet effet, la région d'intérêt (ROI) est une zone spécifique à l'intérieur de l'image que nous voulons étudier d'une manière plus profonde. Elle est mise en évidence par la sélection de la partie de l'image qui nous intéresse et sa séparation du reste de celle-ci. Cela nous permet d'éviter de faire des traitements sur les parties inutiles de l'image, réduisant ainsi le temps de calcul. Le deuxième avantage est de faire éviter aux traitements, se basant sur les approches globales, d'utiliser les niveaux de gris des régions non pertinentes, rendant ainsi les résultats des traitements utilisant ce type d'approche plus performants.

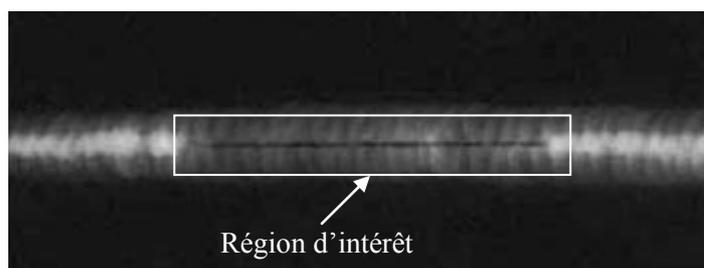


Fig. I.18 Défaut de soudure et région d'intérêt

Dans notre travail, l'intérêt porte beaucoup plus sur l'interface entre la zone du joint soudé et la zone du défaut. La limitation de l'image à cette région empêche la détection des faux défauts en dehors de la soudure. Au cours de l'exécution des différentes tâches édictées par la chaîne de vision, l'image considérée est en fait la région d'intérêt de l'image en question.

I.2.4.2 Modèle du bruit et filtrage

Toutes les images radiographiques obtenues dans les systèmes d'imagerie à rayons X ou gamma contiennent des fluctuations aléatoires dues aux statistiques de l'absorption du quantum de rayonnement. Ce bruit peut entraver la fiabilité de la détection de petites discontinuités. Dans les images film-écran numérisées, d'autres sources dues au numériseur, la structure de l'écran fluorescent renforçateur et la granularité de l'émulsion du film contribuent au bruit. La présence de ce dernier donne à l'image un aspect tacheté, grenu, texturé ou neigeux. Pour la tacheture due au rayonnement diffusé, il a été observé, que le processus de bruit fondamental est dû à la nature discrète des photons de rayons X dans un système d'imagerie et donc admet une distribution de loi de Poisson ou de Gauss. Le bruit des grains du film peut être modélisé par une distribution Gaussienne de moyenne nulle. Le bruit de la radiographie, qui est une combinaison des deux types précédents de bruit, peut être considéré comme un bruit multiplicatif ou signal-dépendant [13]. Dans certains travaux [58], les auteurs ont présenté une approche de modélisation du bruit radiographique par des mélanges de Gaussiennes, ayant une moyenne nulle et une variance variable, donnant une estimation du bruit de dispersion.

Donc, selon les caractéristiques du bruit radiographique, des filtres tels que les filtres gaussiens les filtres de Kalman peuvent être appliqués. Il est à noter aussi que l'image du film peut présenter un bruit impulsif dont la cause est parfois l'attaque du film par les produits chimiques contenus dans la solution de révélation. Dans ce cas, un filtre médian peut être appliqué.

I.2.4.3 Rehaussement du contraste

Le but du rehaussement du contraste est d'améliorer la visibilité de l'image d'entrée, mettant en valeur les régions du défaut. Ceci permet à l'étape de l'extraction du défaut de mieux trouver et représenter chaque défaut dans l'image.

Il existe une collection de techniques qui ont pour but d'améliorer l'apparence des images numériques ou les transformer en rendant leurs apparences meilleures pour les traitements qui sont en aval. Il existe plusieurs techniques pour rehausser le contraste. Les techniques les plus répandues utilisent le recadrage de dynamique et l'égalisation de l'histogramme. Le recadrage de dynamique est l'application d'une transformation dans le but est de redistribuer les niveaux de gris de l'image afin de leur faire occuper une bande de valeurs plus large [23]. Cependant il est bien reconnu que l'utilisation des informations globale est souvent insuffisante pour obtenir un bon rehaussement. Pour y remédier, des techniques de rehaussement adaptatives ont été proposées dans cette application telles que celles basées sur : les propriétés statistiques de l'image dont la moyenne et la variance [23], la mesure d'hétérogénéité [59,16], la morphologie mathématique, etc.

I.2.5 Segmentation, extraction de caractéristiques et interprétation

Ces parties du système de vision dédié aux images radiographiques des défauts de soudures feront l'objet des prochains chapitres de cette thèse. Des méthodes de segmentation d'images basées sur des approches statistiques seront proposées dans le but de détecter le défaut de soudure, s'il existe, dans le film radiographique. Plusieurs défauts représentant les quatre

classes de défauts citées dans §I.1.7 seront extraits. L'extraction de caractéristiques sur ces défauts constituera une base indexée sur laquelle un système de recherche d'images basée sur le contenu sera utilisé dans le but d'accéder au défaut recherché. L'indexation et la recherche d'image seront traitées dans la deuxième partie du manuscrit.

I.3 Conclusion

Dans ce chapitre, nous avons donné un aperçu sur le soudage, le contrôle non destructif par radiographie et les discontinuités les plus prépondérantes dans le soudage ainsi que la description de l'apparence de quelques unes d'entre elles dans la radiographie industrielle. Aussi, le schéma général du système de vision par ordinateur adopté pour la détection et l'identification des défauts de soudures a été présenté.

Des opérations de prétraitement spécifiques aux images radiographiques ont été énumérées. L'opération qui succède à la numérisation du film est la sélection de la région d'intérêt représentant l'endroit où la présence du défaut est la plus probable. Viennent après les opérations de rehaussement de contraste et de filtrage de bruit pour améliorer la visibilité de l'image de la région du défaut. Cette étape est souvent préconisée pour augmenter l'efficacité des méthodes de segmentation d'images, en particulier le seuillage.

Première partie

SEGMENTATION D'IMAGES RADIOGRAPHIQUES BASEE SUR DES APPROCHES STATISTIQUES

Un domaine de recherche important en vision artificielle est la segmentation d'image. Celle se rapporte au processus de partitionnement d'une image numérique en plusieurs régions. Le but de la segmentation est de simplifier et/ou changer la représentation d'une image en une entité plus significative et plus facile à analyser [60]. Ceci est réalisé soit en divisant les images en régions sémantiques contiguës, soit en extrayant un ou plusieurs objets spécifiques dans les images, à l'exemple des défauts de soudures dans le cadre de notre application.

Le résultat de la segmentation d'images est un ensemble de régions qui recouvrent collectivement l'image entière, ou un ensemble de contours extraits à partir de l'image. Chacun des pixels dans une région sont similaires en ce qui concerne une certaine caractéristique ou propriété calculée, comme la couleur, l'intensité, ou la texture. Les régions limitrophes sont sensiblement différentes en ce qui concerne les mêmes caractéristiques.

En d'autres termes, si I est une image composée de N sous-ensembles (I_1, I_2, \dots, I_N) formant une partition et P un prédicat d'uniformité, alors :

$$\bigcup_1^N I_i = I;$$

$$\forall(i, j), i \neq j, I_i \cap I_j = \phi;$$

$$\forall I_i, P(I_i) = \text{vrai};$$

$$\forall(i, j), I_i \text{ spatialement adjacent à } I_j, P(I_i \cup I_j) = \text{faux}$$

La tâche de segmentation d'image est, en général, très difficile à réaliser puisque les images naturelles sont diverses, complexes et la manière de les percevoir varie selon les individus.

C'est pourquoi, plusieurs algorithmes et techniques sont développés dans ce domaine où, actuellement, des milliers de références bibliographiques sont dénombrés présentant des centaines de méthodes. Puisqu'il n'y a aucune solution générale au problème de segmentation d'image, ces techniques doivent souvent tenir compte des spécificités de l'image à traiter (richesse en texture d'orientations et d'échelles différentes, transitions floues entre régions, etc.), du type d'indices visuels à extraire (contours, régions uniformes au sens de niveau de gris, textures; points caractéristiques ; formes) ; de la nature du problème à résoudre en aval de la segmentation (reconnaissance des formes, interprétation, contrôle de qualité, suivi automatique d'objets, etc.) et des contraintes d'exploitation (complexité algorithmique, fonctionnement en temps réel, contraintes matérielles liées au systèmes d'acquisition, capacité de stockage, etc.) [61]. De plus la segmentation d'image demeure un problème mal posé au sens d'Hadamard à cause de la non-unicité, de l'incertitude et de l'instabilité des solutions par rapport aux données d'entrée. Dans beaucoup d'applications y compris la notre, les problèmes liés à la segmentation d'images sont souvent dus à un faible contraste, à des contours flous ou à des intensités trop similaires aux objets avoisinants ce qui rend les contours des objets d'intérêt difficiles à définir, même manuellement. Ces problèmes doivent être résolus avec le plus grand soin car le résultat obtenu à l'issue de cette étape conditionne fortement la qualité finale de l'interprétation.

Parmi les informations pertinentes que peut nécessiter une analyse d'image radiographique, nous trouvons les contours. De façon simple le contour peut être défini comme une grande transition des niveaux de gris dans l'image. C'est ce que détectent les opérateurs de contours

comme les filtres de Prewitt, Sobel, ou encore le gradient à l'exemple de la figure ci-dessous. Dans cette image, les contours du défaut apparaissent mais pas seulement ceux là. Donc, ce qu'on a fait : c'est extraire les contours d'une image mais dans le cas où un objet appartenant à une image doit être isolé, la détection du contour par filtrage n'est plus suffisante car il s'agit ici d'extraire le contour de l'objet [62]. En effet, sur quels critères pouvons nous affirmer que tel pixel appartient ou non au bord du défaut dans l'image de la figure ci-dessous ? Les modèles déformables sont une solution à ce type de problèmes : en initialisant un contour dans l'image de façon relativement grossière, il est possible de le déformer de sorte qu'il se positionne sur les bords de l'objet d'intérêt.



Image en niveaux de gris



Carte de contours gradient

Maintenant, si ces modèles déformables ou contours actifs exploitent uniquement l'information sur le contour, leur évolution vers les bords réels de l'objet peut être amoindrie ; c'est pourquoi, tenir compte en plus de l'information sur la région dans un cadre statistique peut être salutaire, surtout pour les images à fort bruit et à faible contraste. Cela justifie notre option, dans le chapitre 2, pour une méthode de contour actif basé région.

D'autre part, dans une ROI, l'apparence sombre du défaut de soudure par rapport au fond peut être exploitée pour justifier le choix de méthodes de seuillage, où l'intensité du pixel peut être utilisée comme paramètre distinctif. Ce choix a été matérialisé dans le chapitre 3, où neuf méthodes de seuillage issues d'approches différentes (regroupement (ang. *clustering*), entropie, moments, spatialité, voisinage) ont été appliquées et évaluées sur les ROIs des radiogrammes de soudures.

Dans un autre volet où l'on considère l'image radiographique de la soudure dans sa totalité et non pas une ROI, en plus de la connaissance parfaite de la géométrie du défaut, sa localisation par rapport au cordon de soudure et au métal de base s'avère une étape indispensable pour apprécier la qualité de la soudure qui peut être exploitée au moins dans les perspectives pour cette thèse.

Par ailleurs, pour la segmentation en plusieurs régions, les méthodes basées sur la classification des pixels sont largement étudiées à l'instar des K-means, les modèles de mélanges qui utilisent souvent la loi gaussienne. Dans le chapitre 4, nous proposons de développer et appliquer sur nos images la dernière approche utilisant la distribution gaussienne généralisée qui a une propriété intéressante à savoir la flexibilité.

Chapitre 2

Segmentation d'images par modèle déformable probabiliste

II.1 Introduction

Dans les quatre dernières décennies, la segmentation d'images par ordinateur a joué un rôle de plus en plus important dans plusieurs domaines tels l'imagerie médicale et satellitaire, le contrôle de qualité, etc. La segmentation d'images demeure, cependant, une tâche difficile, due à la variabilité énorme de l'objet et la variation de la qualité d'image. En particulier, les images de radiographie de soudures sont souvent entachées de bruit et d'artefacts qui peuvent, en appliquant des techniques classiques de segmentation telles que la détection de contour, occasionner des difficultés considérables. Par conséquence, ces techniques échouent complètement ou exigent certaines étapes de post-traitement pour éliminer les frontières incorrectes des objets (branches pendantes) dans les résultats de segmentation.

Pour surmonter ces difficultés, des modèles déformables ont été intensivement étudiés et largement utilisés dans la segmentation d'image. L'intérêt majeur de cette approche est qu'elle exploite un contour déjà fermé et la connexité n'est plus à vérifier lorsque l'opération est terminée, contrairement aux détecteurs de contours traditionnels. Il est important de noter que ce type d'approche est particulièrement bien adapté à la segmentation d'un objet dans une image.

Les modèles déformables sont des courbes ou des surfaces définies à l'intérieur du domaine d'image qui peut se déplacer sous l'influence des forces internes, qui sont définies sur la courbe ou la surface elle-même, et des forces externes, qui sont calculées à partir des données de l'image.

Les forces internes sont conçues pour maintenir le modèle lisse pendant la déformation. Les forces externes sont définies pour déplacer le modèle vers la frontière de l'objet ou autres attributs désirés dans une image. En contraignant des frontières extraites d'être lisses et incorporant d'autres informations préalables sur la forme d'objet, les modèles déformables offrent la robustesse aux lacunes de bruit et de frontière d'image et laissent l'intégration des éléments de la frontière dans une description mathématique logique et cohérente. Une telle description de frontière peut alors être aisément employée par des applications diverses.

La popularité des modèles déformables est en grande partie due à l'influent article "Snakes: Active Contours" de Kass, Witkin et Terzopoulos [63]. Depuis sa publication, les modèles déformables se sont développés pour être l'un des secteurs de recherches les plus actifs et les plus réussis dans la segmentation d'image. Divers appellations, telles que « snakes », contours actifs, ballons, et contours déformables, ont été utilisées dans la littérature pour se référer aux modèles déformables.

On peut distinguer deux grandes approches pour les contours actifs : l'approche contour en ce sens qu'ils tiennent compte uniquement de l'information présente sur les contours des objets à segmenter. Le modèle de Kass fait partie de cette approche. Ces modèles peuvent être adaptés à certaines classes de problèmes mais peuvent être mis en échec en présence de fort bruit. Dans §II.2, le modèle de Kass et la description des contours actifs basés contour seront présentés.

D'un autre côté, les approches régions s'intéressent à l'intérieur et à l'extérieur de la région définie par le contour actif. Ces approches permettent de résoudre des problèmes pour lesquels il est difficile d'extraire le contour de l'objet. Cela correspond à des situations où les images sont fortement bruitées, floues, etc., à l'exemple des images de radiographie de soudures (voir Fig. I.4 à Fig. I.7) dont les caractéristiques sont citées dans le chapitre 1. Les approches basées région peuvent reposer sur une modélisation statistique des régions à segmenter. Nous revenons sur cette approche dans §II.3.

II.2 Contours actifs basés contour

On peut distinguer dans les contours actifs basée sur l'approche contour deux grandes catégories : les modèles déformables paramétriques et les modèles déformables géométriques.

II.2.1 Modèles déformables paramétriques

Les modèles déformables paramétriques ont gagné une attention significative dans toute la communauté de traitement d'images depuis sa première introduction par Kass et al. [63].

Le critère selon lequel le processus de déformation fait évoluer le contour a été associé à la minimisation d'une fonctionnelle directement interprétable en termes de contraintes physiques. La convergence du contour vers la frontière recherchée dans l'image est alors vue comme une condition de stabilité. La représentation de la courbe explicitement sous sa forme paramétrique pendant la déformation permet une interaction directe avec le modèle et peut mener à une représentation compacte pour une exécution rapide en temps réel. L'adaptation de la topologie du modèle, cependant, comme étapes de séparation et fusion pendant la déformation, peut être difficile en utilisant les modèles paramétriques.

II.2.1.1 Contour actif classique

Le contour actif paramétrique est modélisé par une courbe paramétrée Γ , qui associe à un paramètre spatial p un point $\mathbf{x} = (x, y)^T$:

$$\begin{aligned} \Gamma : \Omega &\rightarrow \mathbb{R}^2 \\ p &\rightarrow \Gamma(p) = (x(p), y(p))^T \end{aligned} \tag{II.1}$$

où x et y sont continument dérivables par rapport à p . Le domaine de définition du paramètre p est normalisé: $\Omega = [0,1]$. La courbe Γ est généralement simple (elle ne présente pas d'auto-intersection). Bien que ce ne soit pas imposé par la modélisation, un des avantages des modèles

déformables est de pouvoir générer des contours fermés. Dans ce cas, la courbe vérifie $\Gamma(0) = \Gamma(1)$.

Au contour continu Γ défini précédemment, on associe la fonctionnelle suivante

$$E(\Gamma) = \alpha \int_0^1 \left| \frac{\partial \Gamma(p)}{\partial p} \right|^2 dp + \beta \int_0^1 \left| \frac{\partial^2 \Gamma(p)}{\partial p^2} \right|^2 dp + \lambda \int_0^1 g(|\nabla I(\Gamma(p))|) dp \quad (\text{II.2})$$

avec α , β et λ des constantes positives.

Les deux premiers termes de l'intégrale sont associés à l'énergie interne du contour qui imposent une contrainte de régularité sur le contour et définissent son élasticité (premier terme) et sa rigidité (second terme) tandis que le troisième terme représente l'énergie externe du contour et qui est un terme d'attache aux données qui va permettre d'attirer le contour actif vers les points de fort gradient de l'image. La fonction I représente l'image et la fonction g est une fonction positive et strictement décroissante. Dans l'article de Kass et al. [63], g est choisie comme $g(|\nabla I|) = -|\nabla I|^2$. Une fonction typique de d'énergie externe conçue pour mener un contour déformable vers des bords est souvent prise comme

$$E_{\text{ext}}(\Gamma) = - \int_0^1 |\nabla(G_\sigma * I)(\Gamma(p))|^2 dp \quad (\text{II.3})$$

où G_σ est la gaussienne centrée d'écart type σ . ∇ est l'opérateur gradient, et $*$ l'opérateur de convolution.

En résumé, minimisant la fonctionnelle d'énergie $E(\Gamma)$ est assujetti d'une part, aux forces internes qui maintiennent la continuité de la courbe (forces d'élasticité) et la préservent d'une courbure excessive (forces de courbure) et d'autre part, aux forces externes qui attirent la courbe vers les frontières désirées de l'objet. Le but est donc de trouver un contour actif $\Gamma^*(p)$, qui minimise $E(\Gamma)$.

Résolu par une méthode variationnelle, le minimum de $E(\Gamma)$ doit satisfaire l'équation d'Euler-Lagrange suivante :

$$\frac{\partial}{\partial p} \left(\alpha \frac{\partial \Gamma(p)}{\partial p} \right) - \frac{\partial^2}{\partial p^2} \left(\beta \frac{\partial^2 \Gamma(p)}{\partial p^2} \right) - \nabla E_{\text{ext}} = 0 \quad (\text{II.4})$$

Pour être perspicace au sujet du comportement physique des contours déformables, nous pouvons considérer (II.4) comme équation d'équilibre de force

$$F_{\text{int}}(\Gamma) + F_{\text{ext}}(\Gamma) = 0 \quad (\text{II.5})$$

où la force interne est donnée par les deux premiers termes de (II.4) tandis la force externe est donnée par le dernier terme.

Pour trouver une solution pour (II.4), le contour déformable doit évoluer dynamiquement en traitant $\Gamma(p)$ comme une fonction de temps t au même titre que p , i.e. $\Gamma(p,t)$. La dérivée partielle de Γ par rapport à t est alors mise égale au côté gauche de (II.4) comme suit :

$$\gamma \frac{\partial \Gamma(p)}{\partial t} = \frac{\partial}{\partial p} \left(\alpha \frac{\partial \Gamma(p)}{\partial p} \right) - \frac{\partial^2}{\partial p^2} \left(\beta \frac{\partial^2 \Gamma(p)}{\partial p^2} \right) - \nabla E_{\text{ext}} \quad (\text{II.6})$$

Le coefficient γ est introduit pour rendre l'unité du côté droit homogène avec le côté gauche. Lorsque la solution $\Gamma(p,t)$ se stabilise, le côté gauche disparaît et la solution de (II.4) est atteinte. Une solution numérique de (II.6) peut être obtenue en discrétisant l'équation et résolvant le système discret itérativement [63]. Malgré l'intérêt que ce modèle a suscité dans la communauté des chercheurs en segmentation d'images, il présente certaines difficultés liées principalement aux choix des paramètres, l'influence de l'initialisation sur la convergence du contour actif [64] et l'incapacité de dernier de progresser dans des concavités prononcées [65]. Dans le but de dépasser ces problèmes, de nombreuses améliorations [66-71] ont été proposées, en utilisant comme forces externes : les forces de pression [66], le flot de vecteur gradient [70], etc.

II.2.1.2 Forces de pression

Cohen [66] a proposé d'augmenter l'intervalle d'attraction du contour actif en utilisant une force de pression ainsi qu'une force de potentiel gaussienne. La force de pression peut gonfler ou dégonfler le modèle ; par conséquent, elle enlève la condition d'initialisation du modèle à proximité des frontières désirées d'objet. Les modèles déformables qui utilisent des forces de pression sont également connus comme ballons [66]. La force de pression est définie comme

$$F_p(\Gamma) = \omega_p N(\Gamma) \quad (\text{II.7})$$

où $N(\Gamma)$ est vecteur normal unitaire au point \mathbf{x} et ω_p est un paramètre de poids constant.

Le signe de ω_p détermine si on gonfle ou on dégonfle le modèle et elle est typiquement choisie par l'utilisateur. La valeur de ω_p détermine l'amplitude de la force de pression. Elle doit être soigneusement sélectionnée de sorte que la force de pression soit légèrement plus petite que la force de gradient, mais assez large pour passer à travers de faux et faibles contours.

Quand le modèle se déforme, la force de pression continue à gonfler ou à dégonfler le modèle jusqu'à ce qu'elle soit arrêtée par la force de gradient. Un inconvénient dans l'emploi des forces de pression est qu'il arrive que le contour déformable se croise et forme ainsi des boucles [72].

II.2.1.3 Flot de vecteur gradient

Xu et Prince [70] expriment la même volonté d'étendre la zone d'atteignabilité du contour actif. Pour cela, ils utilisent une équation de diffusion vectorielle qui diffuse le gradient d'une image vers des zones distantes des frontières. La nouvelle expression du champ de force est appelée

flot de vecteur gradient (ang. *Gradient vector flow* (GVF)). La force externe est remplacée par un champ de vecteur $V(x,y) = [u(x,y) \ v(x,y)]$ qui minimise la fonctionnelle d'énergie :

$$\mathcal{E} = \iint \mu (u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla f|^2 |V - \nabla f|^2 dx dy \quad (\text{II.8})$$

où μ est un paramètre de régulation et f la carte de contour prenant de fortes valeurs sur les zones d'intérêt. La minimisation de (II.8) aboutit aux équations d'Euler :

$$\begin{cases} \mu \nabla^2 u - (u - f_x)(f_x^2 + f_y^2) = 0 \\ \mu \nabla^2 v - (v - f_y)(f_x^2 + f_y^2) = 0 \end{cases} \quad (\text{II.9})$$

où ∇^2 représente l'opérateur Laplacien et f_x, f_y les dérivées de f par rapport à x et y respectivement. Le système d'équations (II.9) peut être résolu en traitant u et v comme fonctions du temps [70]. La méthode GVF agrandit la zone d'influence du gradient de l'image permettant ainsi, l'obtention d'une bonne convergence du contour actif sur des objets possédant des frontières concaves. L'avantage principal par rapport au ballon est qu'il n'est pas nécessaire de connaître la position initiale par rapport à la solution, le sens de la force étant déterminé par la diffusion.

II.2.2 Modèles déformables géométriques/géodésiques

Les modèles déformables géométriques sont représentés implicitement comme des ensembles de niveaux de fonctions de distances 2-D qui évoluent selon une formulation Eulérienne [73]. Ils peuvent automatiquement manipuler des changements de topologie dans une image et tenir compte des multiples estimations simultanées de la frontière d'objet. En outre, ils ne sont pas sensibles aux positions initiales du contour contrairement aux modèles déformables paramétriques. Cependant, en raison de leur complexité de calcul, leur vitesse de convergence est plus lente que les modèles déformables paramétriques.

II.2.2.1 Méthode des ensembles de niveaux

L'idée principale de la méthode des ensembles de niveaux est qu'une courbe peut être considérée comme le niveau 0 d'une fonction de dimension plus élevée $\phi(\mathbf{x}, t)$ [74].

Pour une image I de support $\Omega \subset \mathbb{R}^2$, on considère $\phi : \mathbb{R}^2 \times \mathbb{R}^+ \rightarrow \mathbb{R}$ tel que :

$$\Gamma(p, t) = \{\mathbf{x} | \phi(\mathbf{x}, t) = 0\} \quad (\text{II.10})$$

On peut choisir ϕ comme étant la fonction distance signée au contour Γ , tel que pour chaque point \mathbf{x} et $\forall t \geq 0$, la valeur $\phi(\mathbf{x}, t)$ représente la distance signée du point \mathbf{x} au contour $\Gamma(p, t)$. Les valeurs négatives de ϕ étant prises par convention à l'intérieur du contour alors que les valeurs positives sont prises à l'extérieur.

L'évolution du contour actif Γ est régie par une équation différentielle partielle (EDP) de la forme :

$$\begin{cases} \frac{\partial \Gamma(p,t)}{\partial t} = \mathbf{v}(p,t) \\ \Gamma(p,0) = \Gamma_0(p) \end{cases} \quad (\text{II.11})$$

Γ_0 peut être défini manuellement par exemple et \mathbf{v} est la vitesse d'évolution de la courbe.

On peut décomposer la vitesse d'évolution \mathbf{v} du contour selon la tangente unitaire \mathbf{T} et la normale unitaire \mathbf{N} intérieure à la courbe Γ , ce qui donne :

$$\frac{\partial \Gamma(p,t)}{\partial t} = F_T(p,t)\mathbf{T}(p,t) + F_N(p,t)\mathbf{N}(p,t) \quad (\text{II.12})$$

Il est énoncé dans [75] que seule la composante normale affecte la géométrie du contour, la composante tangentielle n'ayant d'incidence que sur sa paramétrisation. La déformation du contour Γ a lieu uniquement dans sa direction normale. La vitesse d'évolution du contour actif peut donc être considérée comme normale au contour. En notant F_N par F on aura

$$\frac{\partial \Gamma(p,t)}{\partial t} = \mathbf{v}(p,t) = F(p,t)\mathbf{N}(p,t) \quad (\text{II.13})$$

Considérant maintenant que Γ est implémenté par une fonction des ensembles de niveaux ϕ , on doit déterminer l'équation d'évolution de ϕ correspondant à (II.13).

En dérivant l'équation suivante par rapport p ,

$$\phi(\Gamma(p,t),t) = 0 \quad (\text{II.14})$$

on obtient

$$\frac{\partial \Gamma(p,t)}{\partial p} \cdot \frac{\partial \phi(\Gamma(p,t),t)}{\partial \mathbf{x}} = 0 \quad (\text{II.15})$$

Ce qui indique que la tangente de Γ , donnée par $\partial \Gamma / \partial p$, est orthogonale au gradient de la fonction d'ensembles de niveaux $\frac{\partial \phi}{\partial \mathbf{x}} = \nabla \phi$. Par conséquent, le gradient $\nabla \phi$ est la normale \mathbf{N} sont colinéaire. Par convention, on écrit

$$\mathbf{N}(p,t) = -\frac{\nabla \phi}{\|\nabla \phi\|} \quad (\text{II.16})$$

Si on dérive maintenant (II.14) par rapport à t , on obtient

$$\frac{\partial \phi(\Gamma(p,t),t)}{\partial t} + \nabla \phi(\Gamma(p,t),t) \cdot \frac{\partial \Gamma(p,t)}{\partial t} = 0 \quad (\text{II.17})$$

En injectant (II.13) et (II.16) dans l'équation précédente, on obtient

$$\frac{\partial \phi(\Gamma(p,t),t)}{\partial t} = F(p,t) \|\nabla \phi(\Gamma(p,t),t)\| \quad (\text{II.18})$$

Cette équation n'est vérifiée que pour les points situés sur le front, i.e. sur le niveau 0 de ϕ . En l'étendant à tous les points \mathbf{x} de Ω , on obtient l'équation d'évolution générale d'un modèle implicite :

$$\frac{\partial \phi(\mathbf{x},t)}{\partial t} = F(\mathbf{x},t) \|\nabla \phi(\mathbf{x},t)\| \quad (\text{II.19})$$

associée à la condition initiale $\phi(t=0) = \phi_0$ où ϕ_0 est une fonction d'ordre 3 dans le cas de notre application telle que $\phi_0(\Gamma_0)=0$.

La plupart du temps, la vitesse F fait intervenir entre autres un terme externe, de type contour ou région, et un terme de courbure. Cette dernière est exprimée en fonction de ϕ par

$$\kappa(\mathbf{x}) = \mathbf{div} \left(\frac{\nabla \phi(\mathbf{x})}{\|\nabla \phi(\mathbf{x})\|} \right) \quad (\text{II.20})$$

L'équation (II.19) est du type Hamilton-Jacobi et peut être réécrite sous la forme :

$$\begin{cases} \phi_t + H(\phi_x, \phi_y) = 0 \\ \phi(\mathbf{x},0) = \phi_0(\mathbf{x}) \end{cases} \quad (\text{II.21})$$

où H désigne l'Hamiltonien et ϕ_t , ϕ_x et ϕ_y sont respectivement les dérivées partielles de ϕ par rapport à t , x et y , et avec $(x,y)^T = \mathbf{x}$.

Pour accélérer l'évolution des ensembles de niveaux, des schémas numériquement efficaces tels la méthode de bande étroite [76,77] et la méthode de *fast marching* [78] sont proposées.

La méthode des ensembles de niveaux présente de nombreux avantages :

- Les changements de topologie sont aisément traités grâce à l'absence de paramétrisation. La courbe peut donc se diviser ou fusionner au cours de l'évolution de ϕ .
- On peut utiliser une grille discrète et choisir des approximations par différences finies pour les dérivées spatiales et temporelles.
- Les propriétés géométriques de la courbe, telles que la courbure ou le vecteur normal qui sont importants pour les contours actifs, peuvent être déterminés simplement à partir de ϕ .
- La formulation n'est pas limitée aux courbes en deux dimensions et peut être facilement étendue aux dimensions plus élevées.

Face à ces avantages, on relève également des inconvénients dont les plus importants sont le temps de calcul qui reste important même en diminuant la complexité et la vulnérabilité face au fort bruit et au faible contraste. Ce dernier point est commun à tous les contours actifs basés contour qui ne tiennent compte que des caractéristiques de l'image le long du contour traduites par la fonction du gradient de l'image et qui ne prennent pas en compte les caractéristiques des régions à l'intérieur et l'extérieur du contour.

II.2.2.2 Modèle déformable géométrique/géodésique

Ces modèles qui sont introduits indépendamment par Malladi et al. [79] et Caselles et al. [80] en s'inspirant des travaux d'Osher et Sethian [74] sur l'équation de la diffusion de la chaleur, sont conçus pour manipuler naturellement les changements topologiques. Il s'agit dans ce cas d'envisager l'évolution de la courbe comme une propagation d'un front d'onde. L'équation d'évolution proposée se présente comme

$$\frac{\partial \Gamma}{\partial t} = g(|\nabla I(\Gamma)|) \kappa \mathbf{N} \quad (\text{II.22})$$

Dans ce cas, les auteurs définissent g par

$$g(|\nabla I(\Gamma)|) = \frac{1}{1 + |\nabla(G_\sigma * I)|^r}, \quad r \in \{1, 2\} \quad (\text{II.23})$$

Cette fonctionnelle permet la segmentation de l'enveloppe convexe des objets. Pour parvenir à la segmentation d'objets non convexes, il a fallu rajouter une constante positive ν dans (II.22). L'équation d'évolution introduite par Casselles et al. [80] est alors :

$$\frac{\partial \Gamma}{\partial t} = g(|\nabla I(\Gamma)|) (\nu + \kappa) \mathbf{N} \quad (\text{II.24})$$

- $\partial \Gamma / \partial t = \kappa$ est l'équation de la chaleur, connue pour ses propriétés géométriques lissantes. En effet, imaginons que la courbe dans Fig. II.1, se déforme selon cette équation. Les flèches représentent la force $\kappa \mathbf{N}$ en différents points de la courbe (courbure positive (resp. négative) aux points des flèches rentrantes (resp. sortantes)).

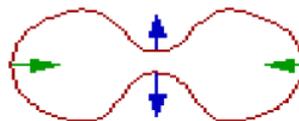


Figure II.1 Courbe se déformant selon sa courbure

La courbure en un point représente l'inverse du rayon de courbure en ce point. On voit que les aspérités tendent à être gommées.

• $v\mathbf{N}$ est une vitesse constante qui agit comme une « force ballon ». Elle pousse la courbe vers l'intérieur ou vers l'extérieur avec la même force en chaque point du contour, et permet à une courbe initialement convexe de devenir non-convexe et de détecter ainsi des objets non-convexes. Cela est nécessaire car selon l'équation de la chaleur, une courbe convexe ne peut que rester convexe.

• $g(|\nabla I(\Gamma)|)$ représente une « fonction d'arrêt » dépendant du contenu de l'image et permet d'arrêter l'évolution de la courbe quand celle-ci arrive sur les frontières de l'objet à détecter. Pour simplifier, désignons $g(|\nabla I(\Gamma)|)$ par $g(I)$.

En résumé, la « force » $(v+\kappa)$ agit comme la force interne dans le modèle classique du snake, le terme de courbure ayant une fonction lissante, et $g(I)$ comme la force externe.

L'équation (II.24) régissant le modèle déformable géométrique peut être réécrite avec le formalisme des ensembles de niveaux comme

$$\begin{cases} \frac{\partial \phi}{\partial t} = g(I) \left(v + \mathbf{div} \left(\frac{\nabla \phi}{\|\nabla \phi\|} \right) \right) \|\nabla \phi\| \\ \phi(\mathbf{x}, 0) = \phi_0(\mathbf{x}) \end{cases} \quad (\text{II.25})$$

Une autre manière de pallier aux problèmes du contour actif classique cités dans la section précédente est proposée par Caselles et al. [81] qui ont introduit le modèle du contour géodésique. Celui-ci correspond au modèle du contour actif classique dans le cas où son terme lié à l'élasticité est éliminé ($\beta = 0$). Ce choix est justifié par le fait que l'effet régularisant des contours actifs provient des flots basés sur la courbure, et de ce fait, le terme de l'élasticité jugé trop contraignant est abandonné. Il a été démontré en utilisant le principe de Maupertuis [82] que la minimisation de l'énergie du contour simplifié (sans le second terme dans (II.2)) est équivalent à la minimisation de la longueur du contour pondéré par une fonction de détection de frontière $g(I)$ dans un espace Riemannien.

$$J(\Gamma) = \int_0^1 g(I) |\Gamma'(p)| dp \quad (\text{II.26})$$

Puisque $|\Gamma'(p)| dp = ds$, on peut écrire :

$$J(\Gamma) = \int_0^{L(\Gamma)} g(|\nabla I(\Gamma(s))|) ds \quad (\text{II.27})$$

avec $L(\Gamma)$ la longueur euclidienne de la courbe Γ et s l'abscisse curviligne de la courbe. La fonctionnelle est intrinsèque, i.e. qu'elle ne dépend pas de la paramétrisation. Le flot du contour peut être décrit comme

$$\frac{\partial \Gamma}{\partial t} = (g(I) \kappa - \nabla g(I) \mathbf{N}) \mathbf{N} \quad (\text{II.28})$$

Dans [83,84], la force de ballon ν [66] est ajoutée. Cette force permet au contour d'évoluer pour permettre de segmenter des formes concaves même si la courbure est nulle. Un modèle plus général du contour géodésique est donc donné par :

$$\frac{\partial \Gamma}{\partial t} = g(I)(\nu + \kappa)\mathbf{N} - (\nabla g(I)\mathbf{N})\mathbf{N} \quad (\text{II.29})$$

Cette équation peut être écrite avec le formalisme des ensembles de niveaux comme

$$\begin{cases} \frac{\partial \phi}{\partial t} = g(I) \left(\nu + \mathbf{div} \left(\frac{\nabla \phi}{\|\nabla \phi\|} \right) \right) \|\nabla \phi\| + \nabla g(I) \cdot \nabla \phi \\ \phi(\mathbf{x}, 0) = \phi_0(\mathbf{x}) \end{cases} \quad (\text{II.30})$$

II.3 Contours actifs basés région

Les régions qu'on désire segmenter peuvent avoir des propriétés (texture, homogénéité, mouvement) qui ne peuvent être incluses dans une intégrale de contour. Le principal objectif des contours basés régions est d'introduire une information globale dans l'équation d'évolution du contour actif en plus de l'information locale procurée par les termes basés contour. L'approche basée région des contours actifs exploite ainsi les caractéristiques des régions intérieures et extérieures au contour. Cette approche permet de résoudre des problèmes pour lesquels il est difficile d'extraire les contours de l'objet. Par exemple, lorsque les images sont fortement bruitées ou floues. Un des premiers modèles déformables basés région est introduit dans les travaux de Cohen et al. [85]. Une intégrale de région apparaît alors dans la fonctionnelle d'énergie, le but étant de reconstruire une frontière séparant deux régions de régularité différente. De façon générale, l'utilisation d'énergies de région permet de mieux prendre en compte les données lorsque l'information de frontière est insuffisante. De plus, elle diminue la sensibilité à l'initialisation dont souffrent les modèles déformables basés uniquement contour. En effet, comme le terme de région est calculé globalement, le contour peut se dilater tant qu'il vérifie un critère d'homogénéité qui peut être fonction de données statistiques sur les intensités des pixels : moyenne, écart-type, variance, etc.

Le modèle du contour actif à anticipation (ang. *anticipating snake*) développé par Ronfard [86] se trouve parmi les premières approches des contours actifs basés région. Il développe un modèle où le contour actif est déformé sous l'action de forces normales au contour dont les intensités sont proportionnelles à la différence entre les caractéristiques statistiques de la région contenant les objets à segmenter et celles de la région du fond.

Suite à ces travaux pionniers, de nombreux approfondissements ont été proposés par plusieurs auteurs pour des applications variées [87-100]. Afin de synthétiser ces approches, nous utilisons ici le formalisme proposé par Jehan-Besson et al. [96].

II.3.1 Approche basée région par le formalisme de Jehan-Besson et al. [96]

Le terme basé contour est défini comme étant une intégrale sur le contour Γ d'un descripteur de contour $k(s, \Gamma)$:

$$J(\Gamma) = \int_{\Gamma} k(s, \Gamma) ds \quad (\text{II.31})$$

où s est l'abscisse curviligne.

De même, le terme basé région est défini comme étant une intégrale sur la région du descripteur de région $k(\mathbf{x}, \Omega)$:

$$J(\Omega) = \int_{\Omega} k(\mathbf{x}, \Omega) d\mathbf{x} \quad (\text{II.32})$$

Lorsque l'on recherche une région homogène, un exemple classique et fondateur proposé par [94] et inspiré de la fonctionnelle de Mumford-Shah [95] peut être considéré. Pour ce critère, on utilise un descripteur statistique de la région : la moyenne $\mu(\Omega)$, et on cherche à minimiser l'écart entre l'intensité et la moyenne par le biais du descripteur suivant :

$$k(\mathbf{x}, \Omega) = (I(x) - \mu(\Omega))^2 \quad (\text{II.33})$$

D'autres critères font intervenir directement la densité de probabilité p d'une caractéristique de l'image $I(\mathbf{x})$ au sein de la région, comme par exemple le score de vraisemblance associé à la densité de probabilité p pour des variables aléatoires indépendantes et identiquement distribuées (i.i.d). Cette mesure peut se formaliser par le biais du descripteur suivant [87,91-93] :

$$k(\mathbf{x}, \Omega) = -\log p(I(\mathbf{x}), \Omega) \quad (\text{II.34})$$

Il est important de noter que souvent les approches région combinent à la fois des termes basés régions et des termes basés contours, principalement pour prendre en compte les caractéristiques des régions et ajouter des contraintes sur le contour.

Prenons l'exemple de la segmentation d'une image en deux régions Ω_{in} et Ω_{ext} où Ω_{in} est la région contenant les objets à segmenter et Ω_{ext} la région du fond comme illustré dans Fig. II.2. L'interface en ces deux ouverts est noté Γ . Ces deux régions forment une partition de l'image, on a donc $\Omega_{in} \cup \Omega_{ext} \cup \Gamma = \Omega_I$ où Ω_I est le domaine de l'image et $\Omega_{in} \cap \Omega_{ext} = \emptyset$. Nous prendrons $\Gamma = \partial\Omega_{in}$.

On peut donc introduire une fonctionnelle générale à minimiser J pour la partition d'une image en deux régions :

$$J(\Omega_{in}, \Omega_{ext}, \Gamma) = \int_{\Omega_{in}} k_{in}(\mathbf{x}, \Omega_{in}) d\mathbf{x} + \int_{\Omega_{ext}} k_{ext}(\mathbf{x}, \Omega_{ext}) d\mathbf{x} + \int_{\Gamma} k_b(s, \Gamma) ds \quad (\text{II.35})$$

Dans ce critère, k_{ext} est un descripteur d'homogénéité du domaine inconnu définissant le fond Ω_{ext} , et k_{in} est un descripteur du domaine inconnu définissant les objets Ω_{in} . k_b représente un

descripteur du contour qui peut être une fonction de régularisation du contour par rapport aux deux termes de régions.

Nous voulons pouvoir considérer des descripteurs d'homogénéité faisant intervenir les caractéristiques des régions (pour k_{in} comme pour k_{ext}) telles que la variance, la moyenne ou l'histogramme de la région. De nombreux descripteurs, tant paramétriques (moyenne, variance, etc. [91,92,101]) que non paramétriques (histogramme, entropie [96,99]), sont donc globalement liés à la région Ω_{in} ou Ω_{ext} . Pour atteindre la solution optimale, il faut déterminer le vecteur d'évolution de Γ à chaque étape en le différenciant par rapport au paramètre d'évolution (temps) t . Les régions deviennent continuellement dépendantes de t . Le calcul de la dérivée Eulérienne du critère $J(\Omega_{ext}(t), \Omega_{in}(t), \Gamma(t))$ dans la direction du champ de vecteur \mathbf{v} a été alors exprimé sous la forme suivante [96] :

$$\begin{aligned}
 dJ(\Omega_{in}(t), \Omega_{ext}(t), \Gamma(t), \mathbf{v}) = & \underbrace{\int_{\Gamma(t)} (k_{ext} - k_{in})(\mathbf{v} \cdot \mathbf{N}) ds}_{(a)} + \underbrace{\int_{\Gamma(t)} (-k_b \cdot \kappa + \nabla k_b \cdot \mathbf{N})(\mathbf{v} \cdot \mathbf{N}) ds}_{(b)} \\
 & + \underbrace{\int_{\Omega_{in}(t)} \frac{\partial k_{in}}{\partial t} d\mathbf{x} + \int_{\Omega_{ext}(t)} \frac{\partial k_{ext}}{\partial t} d\mathbf{x}}_{(c)}
 \end{aligned}
 \tag{II.36}$$

où \mathbf{v} est le champ de vecteurs de vitesse de propagation de $\Gamma(t)$, κ la courbure, \mathbf{N} le vecteur normal unitaire intérieur au contour.

Le terme (a) provient de la variation de la région elle-même et le terme classique (b) provient, quant à lui, de la dérivation, présentée par Caselles et al. [83], du terme de régularisation sur le contour. Les termes (c) représentent la variation des descripteurs en fonction de la région. Ainsi, ces termes sont nuls dans le cas de descripteurs indépendant de la région. En revanche, dans le cas de descripteurs dépendant de la région, ils sont particulièrement importants pour une segmentation précise et robuste.

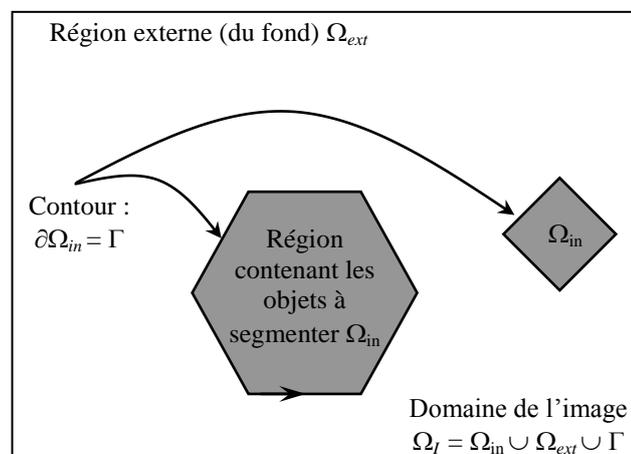


Fig. II.2 Notations pour la segmentation en deux régions.

La dérivation du critère définit la vitesse d'évolution du contour actif. L'équation aux dérivées partielles (EDP) de propagation associée fera décroître le critère d'énergie vers un minimum en utilisant la méthode de la plus grande pente.

Pour déduire \mathbf{v} , il a été démontré que la dérivée Eulérienne de la fonctionnelle $J(\Omega) = \int_{\Omega} k(\mathbf{x}, \Omega) d\mathbf{x}$, où k est un descripteur de région modélisé comme une combinaison linéaire de caractéristiques globalement attachées à la région [102], peut être écrite comme suit :

$$dJ(\Omega, \mathbf{v}) = - \int_{\Gamma(t)} (k(\mathbf{x}, \Omega) + A(\mathbf{x}, \Omega)) \cdot (\mathbf{v} \cdot \mathbf{N}) ds \quad (\text{II.37})$$

où $A(\mathbf{x}, \Omega)$ sont quelques termes issus de la dépendance de k de la région dont l'expression est donnée dans [96]. Alors, la vitesse d'évolution du contour peut être déduite comme

$$\begin{cases} \frac{\partial \Gamma(p, t)}{\partial t} = (k(\mathbf{x}, \Omega) + A(\mathbf{x}, \Omega)) \cdot \mathbf{N} \\ \Gamma(p, 0) = \Gamma_0(p) \end{cases} \quad (\text{II.38})$$

avec $\Gamma_0(p)$ le contour initial défini par l'utilisateur.

Utilisons le formalisme développé plus haut pour donner un aperçu sur quelques méthodes de contours actifs basés région les plus populaires. Ces dernières peuvent être réparties en deux catégories : les approches proposant le calcul de l'équation d'évolution du contour actif en dérivant le critère et les approches proposant de faire évoluer le contour actif vers une solution optimale par le calcul direct de la valeur du critère.

II.3.2 Approches variationnelles avec calcul de l'équation aux dérivées partielles

II.3.2.1 En transformant les intégrales de domaine en intégrales de contours

La plupart des approches proposent de calculer l'équation d'évolution du contour actif en utilisant successivement le théorème de Green-Riemann afin de transformer les intégrales de régions en intégrales de contours puis les équations d'Euler-Lagrange associées à ces intégrales de contours pour calculer l'équation aux dérivées partielles.

Zhu et al. [87] ont présenté un cadre de travail statistique pour la segmentation d'image en utilisant un algorithme appelé « compétition de régions ». Leur but était de combiner les caractéristiques géométriques des contours actifs et les techniques statistiques de croissance de régions. Ils s'intéressent à la segmentation de régions homogènes et introduisent pour une région Ω_i et son contour Γ_i , les descripteurs suivants :

$$\begin{aligned} k(\mathbf{x}, \Omega_i) &= -\log p(I(\mathbf{x})/\psi_i) \\ k_b(s, \Gamma_i) &= \mu_i/2 \end{aligned} \quad (\text{II.39})$$

où p désigne la fonction de densité de probabilité d'appartenance à la région, ψ_i les paramètres associés et μ_i une constante positive. Les auteurs prennent l'exemple d'une distribution gaussienne avec $\psi_i = (\mu_i, \sigma_i^2)$ où désigne la moyenne de la région Ω_i et σ_i^2 sa variance.

Soit M le nombre de régions, ils cherchent alors la partition de l'image et les paramètres des régions qui minimisent le critère de longueur à description minimale (ang. *Minimum Description Length* (MDL)) suivant :

$$J(\{\Omega_i\}_{i=1}^M, \{\psi_i\}_{i=1}^M) = \sum_{i=1}^M \left(\int_{\partial\Omega_i} \frac{\mu_i}{2} ds - \int_{\Omega_i} \log p(I(\mathbf{x})/\Psi_i) d\mathbf{x} + \lambda \right) \quad (\text{II.40})$$

où, λ est une valeur positive représentant la longueur de code nécessaire pour décrire la distribution et le système de codage pour la région Ω_i . Les auteurs font l'hypothèse que cette valeur est la même pour toutes les régions.

Le critère est minimisé en deux étapes. Lors de la première étape, le contour n'évolue pas, les régions Ω_i sont fixées et les paramètres ψ_i sont alors estimés en maximisant les probabilités conditionnelles (dans le cas d'une gaussienne, il suffit d'évaluer la moyenne et la variance de chaque région). La deuxième étape consiste à trouver les régions de l'image minimisant le critère ci-dessus, les paramètres ψ_i étant fixés. Les auteurs cherchent alors l'équation aux dérivées partielles qui va diriger un contour actif vers la partition recherchée.

Afin de dériver le terme basé région $J(\Omega_i) = -\int_{\Omega_i} \log p(I(\mathbf{x})/\Psi_i) d\mathbf{x}$ et de calculer sa contribution dans l'équation d'évolution du contour actif, les auteurs proposent d'utiliser le théorème de Green-Riemann et les équations d'Euler-Lagrange. Dans le cas de deux régions Ω_{in} et Ω_{ext} , i.e. $M = 2$, l'équation d'évolution est la suivante :

$$\begin{cases} \frac{\partial \Gamma(p,t)}{\partial t} = \left(k_{in} - k_{ext} + \frac{\mu}{2} \kappa \right) \cdot \mathbf{N} \\ \Gamma(p,0) = \Gamma_0(p) \end{cases} \quad (\text{II.41})$$

où $k_{in} = -\log p(I(\Gamma(p,t))/\psi_{in})$ et $k_{ext} = -\log p(I(\Gamma(p,t))/\psi_{ext})$.

Dans [93], Paragios et Deriche ont fusionné le modèle précédent avec le modèle de contour actif géodésique/géométrique et la méthode de l'ensemble de niveaux pour définir le modèle des régions actives géodésiques.

Leur méthode de segmentation d'image est capable d'unifier les connaissances basées sur la frontière et la région dans un cadre variationnel et statistique. En effet, l'information de frontière et de région sont basées sur une estimation statistique (MDL et le principe du maximum de vraisemblance (MV)) de l'histogramme de l'image en utilisant un mélange de distributions Gaussiennes ; chacune représentant une région homogène à segmenter. La fonctionnelle d'énergie proposée est minimisée en utilisant la technique des équations d'Euler-Lagrange et la méthode de la descente du gradient pour obtenir un ensemble d'EDPs, chaque EDP agissant sur une frontière, représentée par une fonction d'ensemble de niveaux, d'une région à segmenter. Leur méthode segmente efficacement toutes les régions homogènes dans

les images et présente une bonne robustesse par rapport aux minimums locaux. En outre, les changements de la topologie sont naturellement pris en charge avec la formulation de l'ensemble des niveaux des équations d'évolution.

II.3.2.2 En utilisant les ensembles de niveaux

D'autres approches s'appuient sur l'expression du critère par l'intermédiaire des ensembles de niveaux comme celle de Chan et Vese [94] qui proposent les descripteurs suivants pour la segmentation d'une image en deux régions :

$$\begin{aligned} k_{in}(\mathbf{x}, \Omega_{in}) &= \lambda_1 \|I(\mathbf{x}) - \mu_1(\Omega_{in})\|^2 + \nu \\ k_{ext}(\mathbf{x}, \Omega_{ext}) &= \lambda_2 \|I(\mathbf{x}) - \mu_2(\Omega_{ext})\|^2 \\ k_b(s, \Gamma) &= \mu \end{aligned} \quad (\text{II.42})$$

avec μ_1 la moyenne de la région Ω_{in} , μ_2 la moyenne de la région Ω_{ext} , et ν , μ , λ_1 et λ_2 des constantes positives. Les valeurs de μ_1 et μ_2 sont réestimées au cours de la propagation de la courbe. La méthode des ensembles de niveaux est directement utilisée en représentant la courbe $\Gamma(t)$ comme la courbe de niveau zéro d'une fonction continue $\phi(\mathbf{x}, t)$. Les régions et le contour sont alors exprimés de la manière suivante :

$$\begin{aligned} \Gamma &= \partial\Omega_{in} = \{\mathbf{x} \in \Omega_I / \phi(\mathbf{x}) = 0\} \\ \Omega_{in} &= \{\mathbf{x} \in \Omega_I / \phi(\mathbf{x}) < 0\} \\ \Omega_{ext} &= \{\mathbf{x} \in \Omega_I / \phi(\mathbf{x}) > 0\} \end{aligned} \quad (\text{II.43})$$

L'inconnue recherchée minimisant le critère devient alors la fonction ϕ . Les auteurs introduisent également la fonction de Heaviside H et la mesure de Dirac δ_0 définies respectivement par :

$$H(z) = \begin{cases} 0 & \text{si } z < 0 \\ 1 & \text{si } z \geq 0 \end{cases}, \quad \delta_0(z) = \frac{d}{dz} H(z) \quad (\text{II.44})$$

Le critère est ensuite exprimé par l'intermédiaire des fonctions ϕ , H et δ de la manière suivante :

$$\begin{aligned} J(\phi, \mu_1, \mu_2) &= \int_{\Omega_I} (\lambda_1 \|I(\mathbf{x}) - \mu_1\|^2 + \nu) H(\phi(\mathbf{x})) d\mathbf{x} \\ &+ \int_{\Omega_I} (\lambda_2 \|I(\mathbf{x}) - \mu_2\|^2 + \nu) (1 - H(\phi(\mathbf{x}))) d\mathbf{x} + \int_{\Omega_I} \mu \delta(\phi(\mathbf{x})) \|\nabla \phi(\mathbf{x})\| d\mathbf{x} \end{aligned} \quad (\text{II.45})$$

Afin de calculer les équation d'Euler-Lagrange pour la fonction inconnue ϕ , les auteurs considèrent les versions régularisées des fonctions H et δ notées H_ε et δ_ε .

L'équation d'évolution trouvée est alors directement exprimée avec la fonction des ensembles de niveaux ϕ :

$$\begin{aligned} \frac{\partial \phi}{\partial t} &= \delta_\varepsilon(\phi) \left[\mu \operatorname{div} \left(\frac{\nabla \phi}{\|\nabla \phi\|} \right) + \lambda_1 \|I(\mathbf{x}) - \mu_1\|^2 + \nu - \lambda_2 \|I(\mathbf{x}) - \mu_2\|^2 \right] \quad \text{dans } \Omega_I \\ \frac{\delta_\varepsilon(\phi)}{\|\nabla \phi\|} \frac{\partial \phi}{\partial \mathbf{N}} &= 0 \quad \text{sur } \partial \Omega_I \end{aligned} \quad (\text{II.46})$$

avec $\partial \phi / \partial \mathbf{N}$ la dérivée de ϕ par rapport à la normale intérieure à la courbe \mathbf{N} .

II.3.3 Approches variationnelles sans calcul de l'équation aux dérivées partielles

Certaines approches proposent de faire évoluer le contour actif sans calculer l'équation d'évolution du contour actif. Le critère est évalué de manière à être minimisé à chaque étape. Ainsi, Chakraborty [103] a introduit une approche basée région pour la segmentation d'images médicales. Comme entrées de son algorithme, il considère à la fois l'image I et l'image avec les régions classifiées I_r . Leur terme basé région contraint le contour à entourer une seule région de I_r . Leurs descripteurs sont les suivants, avec la différence qu'ils cherchent à maximiser un critère :

$$\begin{aligned} k_{ext}(\mathbf{x}, \Omega_{out}) &= K_1 I_r(\mathbf{x}) \\ k_{in}(\mathbf{x}, \Omega_{in}) &= 0 \\ k_b(s, \Gamma) &= K_2 I_g(\mathbf{x}) \end{aligned} \quad (\text{II.47})$$

avec K_1 et K_2 deux contraintes positives et I_g l'image du gradient.

Un terme permettant de contraindre le contour à une forme donnée *a priori* est également ajouté dans le critère. Ensuite, les intégrales de régions sont transformées en intégrales de contour par le théorème de Green-Riemann. L'implémentation du contour actif est effectuée en utilisant une paramétrisation de Fourier. L'expression du vecteur vitesse du contour actif n'est pas calculée mais le critère est évalué numériquement de manière à être maximisé. Nous pouvons noter qu'il existe une extension très intéressante de ces travaux en utilisant la théorie des jeux. Les termes basés régions et les termes basés contours sont séparés en deux critères contenant chacun des interactions avec l'autre. Lorsque le jeu progresse, chacun des modules améliore ses positions par partage mutuel de leurs informations.

Une autre approche a été introduite par Chesnaud et al. [90] dans un cadre markovien. Leurs descripteurs statistiques sont réévalués à chaque étape d'évolution du contour actif car ce sont des descripteurs dépendants de la région. Ils choisissent ensuite le déplacement aléatoire qui va permettre de faire décroître le critère.

On peut résumer les avantages des contours actifs basés région dans leur capacité d'arrêter l'évolution de la courbe même en l'absence de la frontière à l'inverse du modèle du contour actif standard et dans leur plus grande robustesse en la présence du bruit par rapport au contour

actif basé contour. Leur limite réside dans le fait que la plupart de ces méthodes nécessitent une information de forme donnée *a priori*, et supposent que les paramètres des lois statistiques sont connus, pour traiter les problèmes d'occultation, de faible contraste d'image ou de la présence d'un fond fortement non homogène. Toutefois, certaines approches pallient à ce problème en supposant qu'aussi bien le contour que les paramètres statistiques sont inconnus. Un exemple de cette approche appliqué dans la radiographie industrielle et utilisant les fenêtres de Parzen est donné dans [20]. Cependant, dans de nombreux cas, les méthodes d'optimisation numériques nécessaires à leurs mises en œuvre requièrent des temps de calcul plus importants ; ce qui est prévisible car les paramètres statistiques inconnus doivent être estimés conjointement à l'optimisation des critères de segmentation [104]. La plupart des modèles de segmentation par contours actifs sont des modèles hybrides dans le sens où ils combinent les descripteurs de régions avec ceux des contours. Les descripteurs basés région sont principalement utilisés pour régir la segmentation et les descripteurs basés contour sont pour la régularisation de la courbe ou l'introduction d'une forme donnée *a priori* pour améliorer la robustesse du modèle de la segmentation par rapport au bruit, au mauvais contraste de l'image et à la position initiale du contour [105].

II.4 Implémentation des contours actifs et représentation par B-splines cubiques

Un des aspects fondamentaux selon lequel les modèles déformables peuvent être classés est la représentation (on parle également d'implémentation). Le choix de la représentation d'un modèle déformable est primordial dans la mesure où il conditionne l'espace des courbes ou des surfaces représentables. Une représentation comporte un ensemble de variables qui sont modifiées itérativement par une méthode d'évolution, l'objectif étant de déterminer les valeurs de ces variables conduisant à la segmentation la plus satisfaisante.

Il existe deux approches principales pour l'implémentation : les approches dites explicites avec une représentation paramétrée du contour et les approches implicites comme la méthode des ensembles de niveaux (voir §II.2.2.1) où le contour est inclus dans une fonction de dimension plus élevée. Les approches paramétriques présentent l'avantage d'être plus rapides en les comparant à la méthode des ensembles de niveaux. En revanche, la gestion des changements de topologie est délicate et des routines spécifiques doivent être implémentées afin de les gérer, contrairement à la méthode des ensembles de niveaux.

Dans les modèles explicites, on distingue notamment, les polygones [63], où le contour peut être représenté par un ensemble de sommets connectés pour former une ligne polygonale, les descripteurs de Fourier et les splines.

La description du contour actif par une structure utilisant les fonctions B-spline permet d'obtenir des courbes avec une régularité qui permet de calculer directement les grandeurs géométriques du contour actif. De plus, ces courbes apportent une flexibilité, une simplicité de modélisation et de bonnes propriétés de régularité qui ont entraîné un grand intérêt pour ce type de modélisation. C'est dans ce cadre que Cohen et al. [66,85] ont introduit la force ballon, applicable à ce genre de courbes. Unser et al. [106,107] ont étudié de façon approfondie les

fonctions splines et sont parvenus à élaborer un modèle de contours actifs exploitant les propriétés intrinsèques de ces courbes. Des B-splines cubiques ont été utilisées pour la représentation des contours actifs par plusieurs auteurs parmi lesquels Figueiredo et al. [92], Precioso [100] et Nacereddine et al. [21]. Ici, nous détaillons les B-splines cubiques qui sont utilisées dans ce manuscrit.

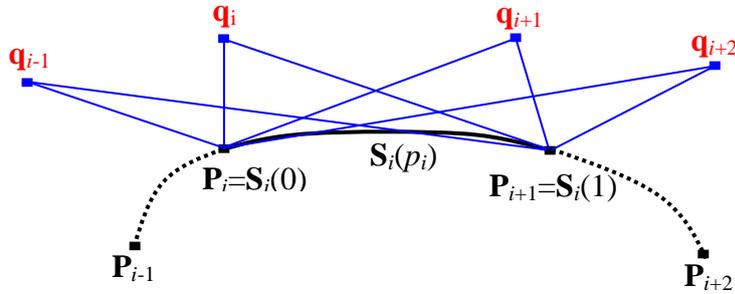


Fig. II.3 Construction d'une B-spline cubique

Les B-splines cubiques sont des fonctions formées de polygones de degré trois. Elles sont définies par une séquence de k points de contrôle $\mathbf{q}_i = (q_x, q_y)$, $0 \leq i \leq k-1$. Le contour, interpolé par une cubique spline, est formé de k segments de courbe, paramétrés par p_0, p_1, \dots, p_{k-1} . Notons $\mathbf{c}_i(p)$ le segment de la courbe paramétrée par p entre les points \mathbf{P}_i et \mathbf{P}_{i+1} , avec $p_i \leq p \leq p_{i+1}$. La courbe Γ passant par une suite de k points \mathbf{P}_i appelés points de jonction. Nous ne considérons que des contours actifs fermés, ainsi nous définissons une continuation périodique de la suite des nœuds telle que $p_k = p_0$. Chaque segment \mathbf{P}_i est une combinaison linéaire de quatre polynômes cubiques du paramètre local p_i :

$$\mathbf{S}_i(p_i) = \mathbf{q}_{i-1}B_{i-2}^3(p_i) + \mathbf{q}_iB_{i-1}^3(p_i) + \mathbf{q}_{i+1}B_i^3(p_i) + \mathbf{q}_{i+2}B_{i+1}^3(p_i) \quad (\text{II.48})$$

où les $B_i^3(p)$ sont les fonctions B-spline cubiques non-uniformes.

Les fonctions B-spline cubiques $B_i^3(p)$, sont des fonctions polynomiales de degré 3, définies par morceaux. On peut, dans le cas de l'interpolation de la suite de points $\{\mathbf{P}_0, \mathbf{P}_1, \dots, \mathbf{P}_{k-1}\}$, en donner une construction simple basée sur la relation de récurrence mise en évidence par de Boor [108] :

$$\begin{aligned} B_i^0(p) &= \begin{cases} 1 & \text{si } p_i \leq p \leq p_{i+1} \\ 0 & \text{ailleurs} \end{cases}, \\ B_i^1(p) &= \frac{p - p_i}{p_{i+1} - p_i} B_i^0(p) + \frac{p_{i+2} - p}{p_{i+2} - p_{i+1}} B_{i+1}^0(p), \\ B_i^2(p) &= \frac{p - p_i}{p_{i+2} - p_i} B_i^1(p) + \frac{p_{i+3} - p}{p_{i+3} - p_{i+1}} B_{i+1}^1(p), \\ B_i^3(p) &= \frac{p - p_i}{p_{i+3} - p_i} B_i^2(p) + \frac{p_{i+4} - p}{p_{i+4} - p_{i+1}} B_{i+1}^2(p), \end{aligned} \quad (\text{II.49})$$

La courbe B-spline est dite uniforme si les paramètres p_i sont régulièrement espacés sur Ω . L'expression d'un point sur le segment \mathbf{S}_i s'écrit

$$\mathbf{S}_i(p_i) = \mathbf{B}(p_i) [\mathbf{q}_{i-1} \quad \mathbf{q}_i \quad \mathbf{q}_{i+1} \quad \mathbf{q}_{i+2}]^T \quad (\text{II.50})$$

avec \mathbf{B} une matrice construite à partir de polynômes cubiques de p

$$\mathbf{B}(p) = \frac{1}{6} \begin{bmatrix} p^3 & p^2 & p & 1 \end{bmatrix} \begin{pmatrix} -1 & 3 & -3 & 1 \\ 3 & 6 & 3 & 0 \\ -3 & 0 & 3 & 0 \\ 1 & 4 & 1 & 0 \end{pmatrix} \quad (\text{II.51})$$

Connaissant l'expression des fonctions B-splines cubiques de paramétrisation uniforme, nous pouvons maintenant expliciter la relation qui lie les k points de contrôle \mathbf{q}_i aux k points d'échantillonnage du contour $\mathbf{P}_i = \mathbf{S}_i(p_i)$ à partir de l'équation (II.48). Cette relation s'écrit sous la forme matricielle comme :

$$\mathbf{P} = W\mathbf{q} \quad (\text{II.52})$$

avec \mathbf{q} le vecteur des points de contrôle, et \mathbf{P} le vecteur des points de jonction correspondants. Pour une courbe fermée la matrice circulante W vaut :

$$W = \begin{pmatrix} 2/3 & 1/6 & 0 & \cdots & 0 & 1/6 \\ 1/6 & 2/3 & \ddots & 0 & \cdots & 0 \\ 0 & \ddots & \ddots & \ddots & 0 & \vdots \\ \vdots & 0 & \ddots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \ddots & \ddots & 1/6 \\ 1/6 & 0 & \cdots & 0 & 1/6 & 2/3 \end{pmatrix} \quad (\text{II.53})$$

La grande précision de l'interpolation fournie par les splines cubiques et le très faible coût de calcul de leur implémentation en font une solution privilégiée au problème de l'interpolation de courbes en général et de la représentation des contours actifs en particulier. De plus, ces courbes ont plusieurs propriétés intéressantes [100,109] que nous allons citer dans ce qui suit :

- Les courbes interpolées, par fonctions B-spline, possèdent une propriété de régularité, appelée propriété fondamentale. Elles minimisent le critère suivant :

$$\int_{\Gamma} \left\| \frac{\partial^2 \Gamma(p)}{\partial p^2} \right\|^2 dp \quad (\text{II.54})$$

sous la contrainte d'interpolation [110]. Rappelons que $\Gamma(p) = (x(p), y(p))$ représente l'expression sous forme paramétrique de la courbe Γ , et $\Gamma''(p)$ la dérivée seconde de $\Gamma(p)$ par rapport à p ; Cette fonctionnelle est, en fait, très proche (du carré) de la courbure κ^2

quand le paramètre p est proche de l'abscisse curviligne, comme démontré dans [107]. Ceci permet de définir les splines, basées sur les fonctions B-splines, comme la solution, au problème de l'interpolation, qui minimise la courbure.

- Les splines sont des polynômes, et étant polynômes elles peuvent être évaluées efficacement sur l'ordinateur.
- Les B-splines (cubiques) sont des polynômes par morceaux, i.e. des fonctions à support local, ce qui les rend très flexibles. En effet, le déplacement d'un point de contrôle n'influence que les segments qui lui sont proches.
- La courbe générée par la B-spline cubique a la propriété intéressante d'être de classe C^2 (deux fois continûment dérivables) aux points de jonctions. Donc le vecteur normal qui apparaît dans l'expression de la force d'évolution ou encore la courbure issue de la pénalisation sur la longueur du contour, peuvent être calculés analytiquement, et donc exactement, en chaque point du contour, en particulier aux points d'échantillonnage.
- Le contour actif est une courbe fermée, ce qui implique la périodicité. Ceci est facilement réalisé en traitant le paramètre p comme périodique.
- Alors que les courbes polygonales ont besoin de termes de régularisation lors de leur évolution, les contours B-splines sont réguliers par nature et ne nécessitent pas de mécanisme de lissage supplémentaire. Cette propriété est importante pour un contour actif. En outre, les B-splines permettent de décrire des courbes lisses avec peu de points de contrôle. Le nombre de variables est donc moins important que pour un contour discrétisé en polygone. Par ailleurs, il est possible d'ajouter des points de contrôles en cours de déformation pour pouvoir ajuster le contour à des données demandant une forte courbure.
- Les splines préservent la forme, ce qui signifie qu'une spline a la même forme que son polygone formé par les points de contrôle. L'image d'une courbe spline, par une transformation affine est une courbe spline. De plus, les coefficients de la courbe spline image sont les images, par la transformation affine, des coefficients de la courbe initiale.

II.5 Evolution du contour déformable et l'approche glouton

Quelle que soit la représentation retenue, il est nécessaire de déformer le modèle utilisé selon un critère faisant intervenir à la fois les données à reconstruire et les contraintes régularisantes [111] de sorte à l'ajuster aux frontières de la ou des structure(s) d'intérêt que l'on souhaite segmenter. Donc, l'évolution du contour actif est formulée comme un problème d'optimisation qui consiste souvent à minimiser une fonctionnelle d'énergie.

La fonctionnelle d'énergie elle-même n'indique pas directement la méthode d'évolution à appliquer. Une équation d'évolution, qui suggère plus ou moins l'algorithme à appliquer aux variables du contour, est dérivée à partir de l'expression de l'énergie. Il faut noter qu'une équation d'évolution peut être donnée sans approche énergétique préalable. Le problème est alors formulé comme la recherche d'un équilibre entre forces internes et externes, notions étroitement liées avec les énergies de même nom [109].

L'équation (II.2) de l'énergie du modèle du contour actif introduit par Kass et al. [63] ne connaît pas de solution analytique. Il est nécessaire de la discrétiser et d'utiliser un schéma

itératif de résolution. La méthode la plus couramment utilisée est de réécrire cette équation comme une équation stationnaire correspondant à un équilibre de forces puis de la discrétiser en utilisant les différences finies. Des méthodes concurrentes comme la programmation dynamique [112] ou les algorithmes gloutons sont également utilisées. Cette dernière approche a été initialement appliquée aux contours actifs 2D par Williams et Shah [67], comme alternative plus rapide et plus simple à l'approche par calcul variationnel par différence finies ou la programmation dynamique.

Nous donnerons dans ce qui suit un aperçu sur cette approche dont le principe a inspiré la méthode d'évolution du modèle déformable utilisé dans ce manuscrit.

L'algorithme glouton (ang. *greedy algorithm*) pour les contours actifs cherche de minimiser l'énergie grâce à un ensemble d'optimisations locales. Il est seulement applicable sur des représentations explicites, où le contour est décrit comme un polygone ou une spline avec n sommets ou points de jonctions $\{\mathbf{P}_i\}_{0 \leq i \leq k-1}$. L'énergie est considérée comme une somme des énergies des sommets :

$$E(\Gamma) = \sum_{i=1}^n E_{\text{sommet}}(\mathbf{P}_i) \quad (\text{II.55})$$

où E_{sommet} est la discrétisation de l'énergie à un sommet donné, en utilisant la méthode des différences finies.

Considérons, par exemple, le terme d'énergie du contour actif dans (II.2), il vient :

$$E_{\text{sommet}}(\mathbf{P}_i) = \alpha \|\mathbf{P}_i - \mathbf{P}_{i-1}\|^2 + \beta \|\mathbf{P}_{i+1} - 2\mathbf{P}_i + \mathbf{P}_{i-1}\|^2 + \lambda g(\mathbf{P}_i) \quad (\text{II.56})$$

Les sommets se déplacent successivement dans le but de minimiser leurs propres énergies. A chaque itération, une fenêtre carrée de largeur m est considérée autour du sommet courant, comme le montre Fig. II.4. L'énergie de ce dernier est calculée à chaque position testée $\tilde{\mathbf{P}}_i$ dans la fenêtre. Le sommet se déplace donc à la position menant à l'énergie la plus basse, qui est peut être résumé par le schéma d'évolution, à l'itération t :

$$\mathbf{P}_i^{(t+1)} = \arg \min_{\tilde{\mathbf{P}}_i \in W(\mathbf{P}_i^{(t)})} E_{\text{sommet}}(\tilde{\mathbf{P}}_i^{(t)}) \quad (\text{II.57})$$

où $W(\mathbf{x})$ est la fenêtre centrée au point \mathbf{x} .

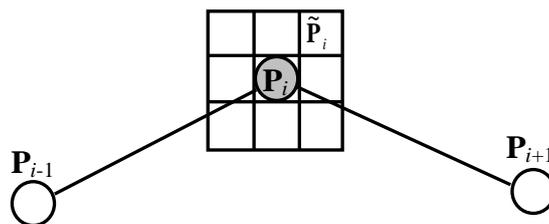


Fig. II.4 Fenêtre carrée 3×3 autour du sommet \mathbf{P}_i

La complexité de l'algorithme glouton initial [67] est de $O(nm^2)$. La taille de la fenêtre a un impact évident sur le coût de calcul, mais aussi sur les capacités de convergence. Des stratégies pour accélérer l'évolution de l'algorithme glouton ont été proposées dans [113] et [114]. L'algorithme glouton est par essence une heuristique d'optimisation discrète.

II.6 Discussions

La partie de l'état de l'art de ce chapitre est consacrée à la description de deux grandes familles de contours actifs à savoir les contours actifs basés contours et les contours actifs basés région. Aussi, des aperçus sur les méthodes de représentation et d'évolution des contours actifs ont été donnés, respectivement, dans les sections §II.4 et §II.5. En effet, lorsque l'on conçoit une méthode de segmentation, il est nécessaire d'effectuer un choix sur la représentation et l'évolution. Le modèle déformable proposé pour notre application et qui sera détaillé dans les sections suivantes, est formulé dans un cadre statistique avec la probabilité *a posteriori* du contour calculée sur un modèle d'image basé région. L'évolution du contour est basée sur l'algorithme glouton. L'information contour pour ce modèle est basée sur la représentation B-spline cubique. Dans ce travail, l'algorithme glouton sera retenu pour faire évoluer la courbe selon deux schémas de déplacement du point de jonction courant :

- autour de son huit-voisinage comme il est illustré dans Fig. II.4, ou
 - dans les deux sens de la direction perpendiculaire au point avec un certain pas qu'on se fixe.
- En outre, une reparamétrisation adaptative de la B-spline cubique selon une stratégie de fusion/division des points de jonctions sera aussi explicitée et implémentée dans les sections suivantes.

II.7 Approche statistique de segmentation par contours actifs

II.7.1 Point de vue énergétique et rôle de la paramétrisation

Du point de vue énergétique, les données et les termes *a priori* sont interprétables en tant qu'énergie externe (par exemple, potentiel) et énergie interne (par exemple, à cause de la tension et la rigidité du contour), respectivement.

Cette perspective a été introduite dans le travail original de Kass [63], où le concept du contour actif ou le modèle déformable a été fait sortir : le contour actif est une spline minimisant une énergie, guidée par les forces de contrainte internes et subissant l'influence des forces de l'image qui l'attirent vers les caractéristiques telles que les frontières.

Depuis son introduction, le concept initial du contour actif a été modifié et amélioré afin de l'adapter aux classes d'images différentes et de surmonter certains de ses inconvénients : à savoir, attraction de contour actif par des artefacts, dégénération du contour actif, convergence et stabilité prématurées du procédé de déformation, « myopie » [92] (i.e., utilisation des données d'image seulement le long du voisinage du contour), initialisation, et évaluation des paramètres de modèle.

Dans les techniques de représentation paramétrée des modèles déformables telles que les descripteurs de Fourier, les splines, les ondelettes et les polygones, le contour lui-même est décrit d'une manière paramétrique. En utilisant des paramétrisations d'ordre réduit, des formes

possibles peuvent être implicitement placées sous une certaine contrainte de régularité ; ceci permet de laisser tomber le terme d'énergie interne (dans le contour actif de Kass et al. [63]) et de formuler le lieu du contour comme un problème d'estimation de paramètres. Cependant, une des difficultés principales de ces techniques est leur manque d'adaptabilité; à savoir, l'ordre de la paramétrisation doit être indiqué *a priori*.

II.7.2 Point de vue Bayésien

On affirme généralement qu'à partir d'un point de vue Bayésien, les contours actifs sont interprétables comme estimateur de contour par maximum *a posteriori* (MAP), où les énergies internes et externes sont associées à la fonction de probabilité *a priori* et à la fonction de vraisemblance (modèle d'observation), respectivement [115,116]. Comme il a été mentionné plus haut, dans les modèles déformables, il est possible de ne pas inclure une énergie de déformation (i.e., une information *a priori* appelée aussi *prior*, du point de vue Bayésien) quand la paramétrisation elle-même garantit régularité/lissage de la forme représentée.

Le modèle statistique *a posteriori* permet d'estimer l'adéquation du contour \mathbf{c} en fonction de la donnée image I . La solution recherchée est le *maximum a posteriori*, c'est à dire le contour maximisant la probabilité du modèle *a posteriori*.

La probabilité *a posteriori* du contour \mathbf{c} étant donné l'image, calculée selon la loi de Bayes, est

$$p(\mathbf{c}/I) = \frac{p(I/\mathbf{c})p(\mathbf{c})}{p(I)} \quad (\text{II.58})$$

où $\mathbf{c} = \{c_0, c_1, \dots, c_{N-1}\}$, ($c_i = (x_i, y_i)^T$) est la version discrétisée du contour Γ , N le nombre d'échantillons de la discrétisation, le modèle *a priori* $p(\mathbf{c})$ est un modèle géométrique qui mesure la qualité de la forme du contour \mathbf{c} en l'absence de données, et le modèle de données $p(I/\mathbf{c})$ décrit comment un contour donné engendre les intensités présentes dans l'image. C'est une description du processus stochastique qui relie l'état inconnu \mathbf{c} aux données I . Elle est donc la probabilité conditionnelle de l'image observée I , étant donné le contour \mathbf{c} qui est aussi appelée la fonction de vraisemblance. Notons que pour une image observée donnée, la probabilité $p(I) = \sum_{\mathbf{c}} p(I/\mathbf{c})p(\mathbf{c})$ est une constante de normalisation. Le modèle *a priori* doit conduire à des probabilités fortes pour des configurations de \mathbf{c} correspondant à une énergie régularisante faible. Ce qui nous permet d'avoir une équivalence entre l'énergie interne (de régularisation) du modèle déformable donnée par les deux premiers termes dans (II.2) et la distribution *a priori* sur le contour. Il est courant d'utiliser une distribution de Gibbs ou Boltzmann de la forme

$$p(\mathbf{c}) = \frac{1}{Z_{\text{int}}} \exp(-E_{\text{int}}(\mathbf{c})) \quad (\text{II.59})$$

où $E_{\text{int}}(\mathbf{c})$ est la version discrétisée de l'énergie interne et Z_{int} est une constante de normalisation, appelée fonction de partition et est donnée par $Z_{\text{int}} = \sum_{\mathbf{c}_j \in \Omega} \exp(-E_{\text{int}}(\mathbf{c}_j))$.

De la même façon, le modèle de données peut s'exprimer en utilisant la distribution de Gibbs si on suppose un modèle d'acquisition basé sur des mesures linéaires avec un bruit Gaussien

$$p(I/\mathbf{c}) = \frac{1}{Z_{ext}(\mathbf{c})} \exp(-E_{ext}(\mathbf{c}, I)) \quad (\text{II.60})$$

$E_{ext}(\mathbf{c}, I)$ est la version discrétisée de l'énergie externe ou le potentiel $E_{ext}(\Gamma)$ dans (II.3), qui est une fonction de $I(x, y)$.

Des modèles peuvent être adaptés en trouvant \mathbf{c} qui maximise localement $p(\mathbf{c}/I)$ dans (II.58). Ceci est connu sous le nom de la solution du maximum *a posteriori*. Avec la construction précédente, mais si et seulement si $Z_{ext}(\mathbf{c})$ est constante [92], cette solution au sens du MAP donne le même résultat qu'une minimisation de l'énergie dans (II.2), la configuration d'énergie du modèle déformable étant donné l'image, i.e.

$$\begin{aligned} \hat{\mathbf{c}}^{MAP} &= \arg \max_{\mathbf{c}} \{p(\mathbf{c}/I)\} = \arg \max_{\mathbf{c}} \{p(I/\mathbf{c})p(\mathbf{c})\} \\ &= \arg \min_{\mathbf{c}} \{E_{int}(\mathbf{c}) + E_{ext}(\mathbf{c}, I)\} \end{aligned} \quad (\text{II.61})$$

Cette approche peut s'avérer intéressante dans le cas où le terme d'attache aux données peut être dérivé en prenant en compte les caractéristiques du bruit lors de l'acquisition dans le modèle de données. Elle permet de quantifier l'incertitude correspondant au modèle *a posteriori*.

La difficulté principale dans cette approche est toujours le choix des paramètres impliqués dans la définition de la fonction de probabilité *a priori* et du modèle d'observation.

Cependant, une interprétation de l'estimation du critère du maximum *a posteriori* par un maximum de vraisemblance (MV) est valide dans le cas où on a un *prior* uniforme sur l'ensemble des valeurs valides des paramètres.

Les avantages les plus importants de l'approche Bayésienne sont les suivants :

- a. il fournit un cadre adéquat pour l'estimation des paramètres du modèle, par exemple, puissance du bruit, distributions des paramètres, coefficients du flou, etc. et,
- b. elle est exempte de la « myopie » qui caractérise les approches du contour actif basé contour (due à la nature locale de l'énergie potentielle), puisque la fonction de vraisemblance considère toutes les données de l'image [92].

II.7.3 Principaux modèles d'images

Dans beaucoup de problèmes d'imagerie, la fonction de probabilité peut être obtenue à partir de la connaissance du mécanisme de génération, plutôt qu'à partir d'autres arguments de sens heuristique. Un cadre statistique est donc, dans ces cas, le choix correct.

Nous pouvons prendre un exemple d'application d'une telle approche en imagerie médicale. Dans [117] la physique utilisé pour générer les images ainsi que la morphologie du cœur jouent un rôle important pour construire le modèle d'images utilisé : les intensités des pixels de

l'image observée sont modélisées par des variables aléatoires distribuées selon la loi de Rayleigh pour laquelle la moyenne dépend de leurs positions par rapport au contour.

Une approche similaire a également été utilisée dans [92] pour la segmentation d'images échographiques cardiaques et d'images à résonance magnétique (IRM) du cerveau et du cœur. Ces deux groupes d'images ont été décrits respectivement par les distributions de Rayleigh et de Gauss.

Dans les images de radar à ouverture synthétique (ROS), la détection de contour est difficile à cause du bruit du *speckle* présent dans ces images. Ce problème a largement été étudié au cours de ces dernières années et beaucoup de solutions ont été proposées. Il est maintenant bien connu que pour obtenir des algorithmes efficaces, les propriétés statistiques du *speckle* doivent être prises en compte [118]. Un modèle simple pour le *speckle* consiste à décrire les niveaux de gris comme étant des variables aléatoires distribuées selon les lois Gamma.

Dans le cas d'images acquises en présence d'un faible flux de photons, le bruit présent peut être correctement décrit par une distribution de Poisson [119]. Ce type d'images peut être rencontré en astronomie où le temps d'exposition du détecteur est court. D'un autre côté, les distributions Gaussiennes peuvent jouer un rôle capital pour modéliser un bon nombre de problèmes physiques à l'instar de l'imagerie radiographique (voir §I.2.4.2).

II.7.4 Approche Bayésienne pour l'estimation du contour

II.7.4.1 Contour discrétisé

Un contour discrétisé \mathbf{c} sur une image est un ensemble de N points équidistants de $\Gamma(p)$ assemblés dans un vecteur ($N \times 2$) $\mathbf{c} = [\mathbf{c}_0^T \cdots \mathbf{c}_{N-1}^T]$ où nous supposons que $N > k$ (souvent, $N \gg k$), et

$$\mathbf{c}_i = [x_i \quad y_i] = \left[x \left(p_0 + \frac{i(p_k - p_0)}{N} \right) \quad y \left(p_0 + \frac{i(p_k - p_0)}{N} \right) \right] \quad (\text{II.62})$$

pour $i = 0, 1, \dots, N-1$.

Les coordonnées des points de contrôle sont arrangées dans un vecteur de paramètres $\mathbf{q}_{(k)} = [\mathbf{q}_0^T \cdots \mathbf{q}_{k-1}^T]^T$ où l'indice (k) est utilisé pour souligner qu'il y'a k points de contrôle, la spline fermée et discrétisée \mathbf{c} peut être obtenu sous forme matricielle comme $\mathbf{c} = \mathbf{B}_{(k)} \mathbf{q}_{(k)}$ où les éléments de $\mathbf{B}_{(k)}$ sont donnés par $[\mathbf{B}_{(k)}]_{il} = \tilde{B}_l^3(p_0 + i(p_k - p_0)/N)$; $l = 1, \dots, k$; avec

$\tilde{B}_l^3(p) = \sum_{j=-\infty}^{j=+\infty} B_{l+j(p_k-p_0)}^3(p)$ une extension de $B_l^3(p)$ au cas périodique de la spline.

En l'absence de contraintes sur les points de contrôle, l'ensemble des splines, avec k points de contrôle et un nombre de fonction de base, constitue un espace vectoriel $\mathcal{R}(\mathbf{B}_{(k)})$ de dimension k et dont la base est $\mathbf{B}_{(k)}$.

II.7.4.2 Modèle d'observation d'image

Soit l'image I (une matrice $w^x \times w^y$ de niveau de gris) une fonction aléatoire de niveaux de gris. Soit \mathbf{c} le contour d'une région connexe R_1 de I et R_2 l'ensemble des points non inclus dans R_1 . Notons z_i le niveau de gris du $i^{\text{ème}}$ pixel de I . $z = \{z_i\}$ l'ensemble de niveaux de gris de l'image, $p(z)$ la densité du niveau de gris et $\psi_z = \{\psi_1, \psi_2\}$ les paramètres de la densité (i.e. $p(z_i) = p(z_i|\psi_1)$ pour $i \in R_1$ et $p(z_i) = p(z_i|\psi_2)$ pour $i \in R_2$).

Du moment où nous prenons comme hypothèses l'indépendance des variables aléatoires de l'image, conditionnées au contour, et l'homogénéité de région, i.e. la distribution de probabilité de chaque pixel dépend seulement du fait que ce dernier appartient à la région R_1 ou R_2 , on peut exprimer

$$p(I|\mathbf{c}) = p(z|\mathbf{c}, \psi_z) = \prod_{i \in R_1} p(z_i / \psi_1) \times \prod_{i \in R_2} p(z_i / \psi_2) \quad (\text{II.63})$$

La probabilité sur l'image $p(I) = \sum_j p(\mathbf{c}^{(j)}) p(I|\mathbf{c}^{(j)})$ est une constante. $\mathbf{c}^{(j)}$ désigne le $j^{\text{ème}}$ contour.

Quant au *prior* sur le contour, on considère dans ce modèle que la régularité du contour provient de la représentation paramétrée du contour par les B-splines. En effet, la propriété fondamentale des splines citée dans §II.4, implique la minimisation du carré de la courbure le long du contour discrétisée \mathbf{c} , i.e. $E_{\text{spline}} \approx \min(E_{\text{courbure}})$ où,

$$E_{\text{courbure}}(\mathbf{c}) = \sum_{i=1}^{N-1} |\kappa_i|^2 = \sum_{i=1}^{N-1} \left| \frac{\mathbf{c}_{i-1} - 2\mathbf{c}_i + \mathbf{c}_{i+1}}{\Delta p^2} \right|^2.$$

Alors, l'utilisation de la B-spline pour représenter le contour peut être traduite comme une introduction d'une probabilité *a priori* sur le contour qui peut être exprimé par

$$p(\mathbf{c}) = \frac{1}{Z} \exp(-E_{\text{courbure}}(\mathbf{c})) \quad \text{où } Z \text{ est une constante appelée fonction de partition (voir §II.7.2).}$$

L'estimation du contour \mathbf{c} au sens du maximum *a posteriori* nous donne

$$\hat{\mathbf{c}}^{\text{MAP}} = \arg \max_{\mathbf{c}} (p(\mathbf{c}|I)) = \arg \max_{\mathbf{c}} (p(I|\mathbf{c})p(\mathbf{c})) \quad (\text{II.64})$$

Dans notre cas, les contours appartiennent à un sous-espace de dimension finie engendré par la base des B-splines. Les propriétés de lissage des contours sont étroitement liées à celles des vecteurs de la base et à la dimension k du sous-espace. Généralement, la dimension de base détermine le contenu en fréquence des contours. Que devrait être la dimension appropriée k du sous-espace ? De point de vue de la minimisation de l'erreur d'interpolation du contour par la B-spline, k devrait être le plus grand possible. Cependant, à mesure que k augmente le sous-espace aura moins de contraintes et les contours estimés plus irréguliers.

Nous abordons l'évaluation de la dimension du sous-espace en supposant ces contours $\mathbf{c}(k, \mathbf{q}(k))$ sont aléatoires, avec une fonction de densité de probabilité de la forme $p(\mathbf{c}(k, \mathbf{q}(k))) = p(k|\psi_{\mathbf{c}})$, où $\psi_{\mathbf{c}}$ désigne un vecteur de paramètres de $p(k|\psi_{\mathbf{c}})$. Cette dernière peut être choisie comme fonction décroissante en k , favorisant ainsi des contours lisses.

Par conséquent, l'estimation du maximum *a posteriori* de la paire (\mathbf{c}, k) est donnée par

$$(\hat{\mathbf{c}}, \hat{k}) = \arg \max_{k, \mathbf{c} \in \mathfrak{R}(\mathbf{B}_{(k)})} p(z|\mathbf{c}, \psi_z) p(k|\psi_c) \quad (\text{II.65})$$

Certes, lorsque k décroît le lissage de la courbe augmente ainsi que $p(k|\psi_c)$; cependant, la fonction de vraisemblance $p(z|\mathbf{c}, \psi_z)$ risque de diminuer car le contour interpolé peut être incapable de décrire la région de l'objet avec précision comme nous le verrons dans la suite. Donc, il faut chercher une valeur de k minimale pour laquelle le contour estimé donne une probabilité *a posteriori* maximale. Deux solutions parmi tant d'autres pour répondre à cette question sont données par Figueiredo et al. [92] et Dias [91] qui considèrent respectivement MDL et la distance de Kullback symétrique dans la formulation de la probabilité *a priori*.

Cependant, pour ces deux méthodes, nous devons choisir empiriquement, les valeurs k_{\min} et k_{\max} et qui correspondent respectivement, aux valeurs minimale et maximale entre lesquelles la valeur optimale du nombre de point de contrôle \hat{k} est supposée être. Non seulement, l'intervalle $[k_{\min}, k_{\max}]$ peut ne pas contenir la valeur de k optimale, mais aussi le temps de calcul risque d'être considérable. Ajoutons à cela que l'augmentation du nombre de points de contrôle se fait sans stratégie de l'emplacement des points ajoutés dans le contour actualisé. En outre, lors de l'évolution du contour les points de contrôle peuvent manquer dans des endroits ou s'entasser dans d'autres.

Pour pallier aux inconvénients cités plus haut, nous proposons dans la section suivante une méthode basée sur la reparamétrisation d'une B-spline cubique selon une stratégie de division/fusion du morceau du contour formé par deux points de contrôle successifs. Dans ce cas, k est supposé connu au départ (un petit nombre de points de contrôle est choisi) mais adapté au fur et à mesure que le contour évolue.

D'après (II.65), l'estimation de (\mathbf{c}, k) au sens du MAP dans le cas où on connaît k , est tout simplement l'estimée du contour au sens du maximum de vraisemblance. De plus si le vecteur de paramètres ψ_z n'est pas connu, l'estimée au sens du MV de (\mathbf{c}, ψ_z) est déterminée par

$$(\hat{\mathbf{c}}, \hat{\psi}_z) = \arg \max_{\mathbf{c} \in \mathfrak{R}(\mathbf{B}_k), \psi_z} \{L(z|\mathbf{c}, \psi_z)\} \quad (\text{II.66})$$

où $L(z|\mathbf{c}, \psi_z) \equiv \log p(z|\mathbf{c}, \psi_z)$ est la fonction de log-vraisemblance. La fonction log est introduite, puisqu'elle n'affecte pas le lieu du maximum et permet une certaine simplification formelle. Puisque résoudre (II.66) par rapport à \mathbf{c} et ψ_z simultanément pourrait être très difficile, nous optons pour une solution sous-optimale donnée par des schémas itératifs du type [92]

$$\hat{\mathbf{c}}^{(t+1)} = \underset{\mathbf{c} \in \mathfrak{R}(B_k)}{\operatorname{argmax}} \left\{ L(z | \mathbf{c}, \hat{\psi}_z^{(t)}) \right\} \quad (\text{II.67})$$

$$\hat{\psi}_z^{(t+1)} = \underset{\psi_z}{\operatorname{argmax}} \left\{ L(z | \hat{\mathbf{c}}^{(t+1)}, \psi_z) \right\} \quad (\text{II.68})$$

où $\hat{\mathbf{c}}^{(t)}$ et $\hat{\psi}_z^{(t)}$ sont les estimations de \mathbf{c} et ψ_z à l'itération t , respectivement.

Le calcul de $(\hat{\mathbf{c}}, \hat{\psi}_z)$ peut être récapitulé dans Algorithme 1 (Algo 1)

Algorithme 1

Initialisation : Poser $\mathbf{c}^{(0)}$, $\psi_z^{(0)}$ et ε

Faire

Etape 1 : $\Delta \mathbf{c}^{(t)} = \underset{u \in \Omega(\mathbf{c}^{(t)})}{\operatorname{argmax}} L(z | \mathbf{c}^{(t)} + u, \psi_z^{(t)})$

où $\Omega(\mathbf{c}) \subset \mathcal{C}^N$ est l'ensemble des points définissant les déplacements sur les 8 voisins pour chacun des points du contour

Etape 2 : $\mathbf{c}^{(t+1)} = \mathbf{c}^{(t)} + \mathbf{B}_{(k)} \Delta \mathbf{c}^{(t)}$

Etape 3 : $\psi_z^{(t+1)} = \underset{\psi_z}{\operatorname{argmax}} L(z | \mathbf{c}^{(t+1)}, \psi_z)$

Etape 4 : $\Delta L = L_{z/\mathbf{c}}^{(t+1)} - L_{z/\mathbf{c}}^{(t)}$

Tant que $|\Delta L| \geq \varepsilon$

II.7.4.2 Reparamétrisation de la B-spline par des opérations de division/fusion

Ici, on prend le déplacement $\Delta \mathbf{c}^{(t)}$ calculé dans les deux sens de la ligne orthogonale au contour comme l'illustre Fig. II.5. Ce choix est justifié dans §II.2.2.1. En outre, avec cette configuration, en utilisant les deux sens de la ligne orthogonale au lieu des huit (8) positions du voisinage, l'espace de recherche est réduit de 1 à 1/4.

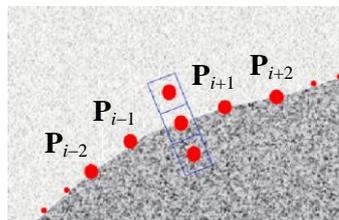


Fig. II.5 Déplacement du point de jonction selon la normale au contour (ici : $\Delta^\perp = \pm 1$)

Nous présentons ici le processus de re-échantillonnage du contour basé sur des opérations de division et fusion pour permettre au contour représenté par la B-spline d'adapter le nombre de points de contrôle nécessaire pour décrire l'objet d'une manière plus précise. La longueur de chaque segment de la courbe (distance entre deux points de contrôle successifs) est utilisée comme critère pour adapter le nombre de points de contrôle.

La création de points de contrôle permet au contour de garder un échantillonnage suffisant lorsqu'il se dilate. A l'inverse, la fusion a pour rôle d'empêcher les points de contrôle voisins d'être trop proches, ce qui risquerait de causer des intersections (boucles) du contour, comme illustré dans Fig. II.6. En effet, si la longueur du segment de la courbe est inférieur à d_m calculée comme le produit de la longueur moyenne l_a de tous les segments de la courbe par un certain seuil de fusion, $\delta_m (<1)$, i.e., $d_m = \delta_m \times l_a$, alors le dernier point de contrôle du segment concerné est éliminé, comme le montre Fig. II.7. Par contre, si la longueur du segment de la courbe dépasse une certaine valeur d_s , où $d_s = \delta_s \times l_a$ avec δ_s comme seuil de division ($\delta_s > 1$), le segment de la courbe est subdivisé en ajoutant un nouveau point de contrôle (voir Fig. II.8). Au début, le contour évolue selon Algo 1, qui utilise l'approche glouton décrite dans §II.5 mais avec un déplacement selon la normale du point de jonction par une distance Δ^\perp (voir Fig. II.5), jusqu'à ce que la différence entre les fonctions de vraisemblance de deux itérations successives, soit inférieure à un certain seuil ε_1 qu'on se fixe, ce qui correspond à l'arrêt de l'évolution du contour. Alors, la fonction de vraisemblance résultante L_1 est sauvegardée. Le processus de division/fusion est alors appliqué sur tous les morceaux du contour, obtenant une nouvelle configuration du contour qu'on va faire évoluer selon Algo 1. Si la différence entre la fonction de vraisemblance résultante et L_1 est inférieure à certain seuil ε_2 , le contour final est obtenu, sinon le contour continue à évoluer selon Algo 1 et le processus de division/fusion est répété jusqu'à ce que le contour n'évolue plus.

II.8 Résultats expérimentaux

L'expression de $\psi_z = \{\psi_1, \psi_2\}$ dépend de la structure de $p(z)$. Par exemple, pour la densité Gaussienne qui est donné par

$$p(z|\psi_z) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\left(\frac{z-\mu}{\sigma\sqrt{2}}\right)^2\right] \quad (\text{II.69})$$

avec une moyenne μ et une variance σ^2 , les estimées de $\psi_i \equiv \{\mu_i, \sigma_i^2\}$, pour $i = 1, 2$, sont données par la moyenne et la variance dans la région respectivement. De même pour une densité de Rayleigh qui est donnée par

$$p(z|\psi_z) = \frac{z}{\phi} \exp\left(-\frac{z^2}{2\phi}\right) \quad (\text{II.70})$$

où $\psi_i \equiv \phi_i$, pour $i = 1, 2$ où ϕ est le vecteur de variance.

Les estimations du contour et des paramètres des régions intérieure et extérieure sont données par l'algorithme 2 (Algo 2).

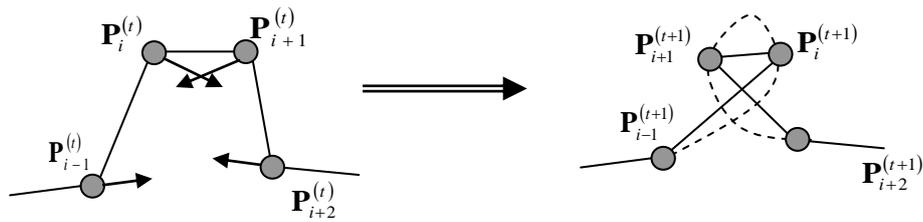


Fig. II.6 Sans mécanisme de fusion, les boucles dans les splines peuvent survenir

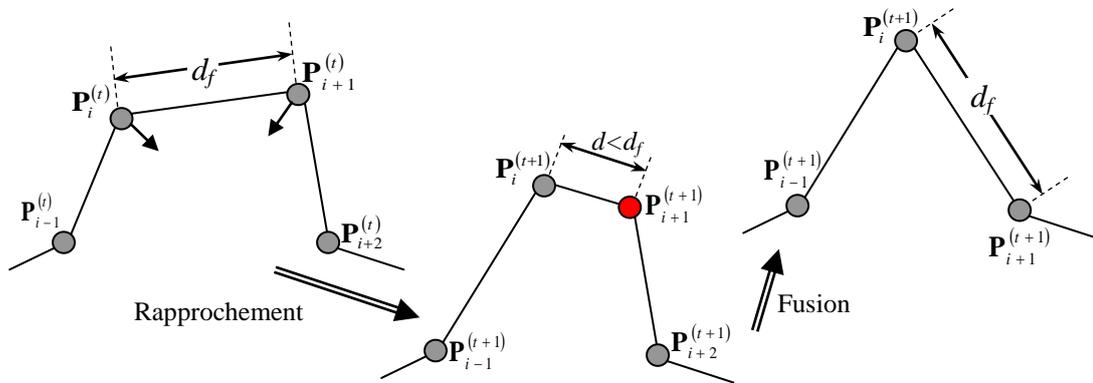


Fig. II.7 A l'itération $t+1$, les points de jonctions P_i et P_{i+1} se rapprochent en dessous de d_f . Il y'a donc fusion

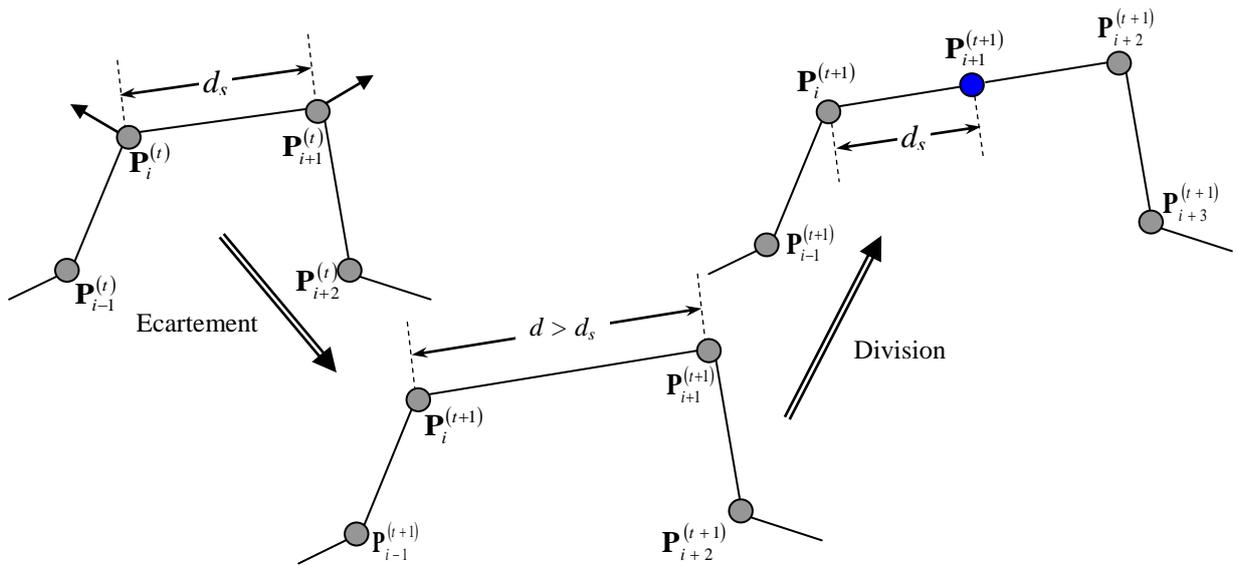


Fig. II.8 A l'itération $t+1$, les points de jonctions P_i et P_{i+1} sont suffisamment éloignés pour qu'un nouveau point de jonction puisse être inséré. Il y'a donc division ou séparation

Algorithme 2

Initialisation : Poser $c^{(0)}, \psi^{(0)}, \varepsilon_1, \varepsilon_2, \delta_d, \delta_f$

Faire (boucle 2)

Faire (boucle 1)

Etape 1 : $\Delta c^{(t_1)} = \arg \max_{u \in \Omega(c^{(t_1)})} L(z / c^{(t_1)} + u, \psi_z^{(t_1)})$
où, $\Omega(c) \subset \mathcal{O}^N$ est l'ensemble des points définissant les déplacements orthogonaux au contour c

Etape 2 : $c^{(t_1+1)} = c^{(t_1)} + \mathbf{B}_k \Delta c^{(t_1)}$

Etape 3 : $\psi_z^{(t_1+1)} = \arg \max_{\psi_z} L(z / c^{(t_1+1)}, \psi_z)$

Etape 4 : $\Delta L_1 = L_{z/c}^{(t_1+1)} - L_{z/c}^{(t_1)}$

Tant que $|\Delta L_1| \geq \varepsilon_1$

$L_{z/c}^{(t_2)} = L_{z/c}^{(t_1+1)}$

Etape 5 : $c^{(t_2)} = \text{division}(c^{(t_1+1)}, \delta_d)$

Etape 6 : $c^{(t_2)} = \text{fusion}(c^{(t_2)}, \delta_f)$

Aller à boucle 1

Déduire $L_{z/c}^{(t_2+1)}$

$\Delta L_2 = L_{z/c}^{(t_2+1)} - L_{z/c}^{(t_2)}$

Tant que $|\Delta L_2| \geq \varepsilon_2$

Nous avons implémentés Algo. 1 sur des images synthétiques simulant les défauts de soudures, ayant des distributions Gaussiennes (IG, JG) et de Rayleigh (IR, JR) dans Fig. II.9, Nous constatons à partir des résultats dans Fig. II.9 la robustesse de cet algorithme à l'initialisation.

Aussi, nous remarquons que malgré le caractère bruité des images considérées, particulièrement pour les images générées par le modèle de Rayleigh, les contours des défauts de soudure sont estimés correctement.

Notons que les objets considérés ne présentent pas des formes complexes et entre 9 et 12 points de contrôle ont été suffisants pour adapter les splines aux contours pour les quatre cas d'images. Cependant, pour cet algorithme, le choix du nombre de points de contrôle doit être fait d'une manière empirique. Dans Fig. II.10, nous examinons l'influence du nombre de points de contrôle k sur l'estimation du contour de l'objet. Les résultats pour $k = 4, 6, 8$ et 10 sont montrés.

Il peut être observé dans l'exemple de Fig. II.10 qu'un résultat satisfaisant est si tôt fourni par huit (8) points de contrôle. Par conséquent, plus de points de contrôle serait clairement inutile car la précision du contour estimé ne sera pas améliorée considérablement. En outre, plus de points de contrôle nécessitera plus de temps d'exécution pour l'algorithme.

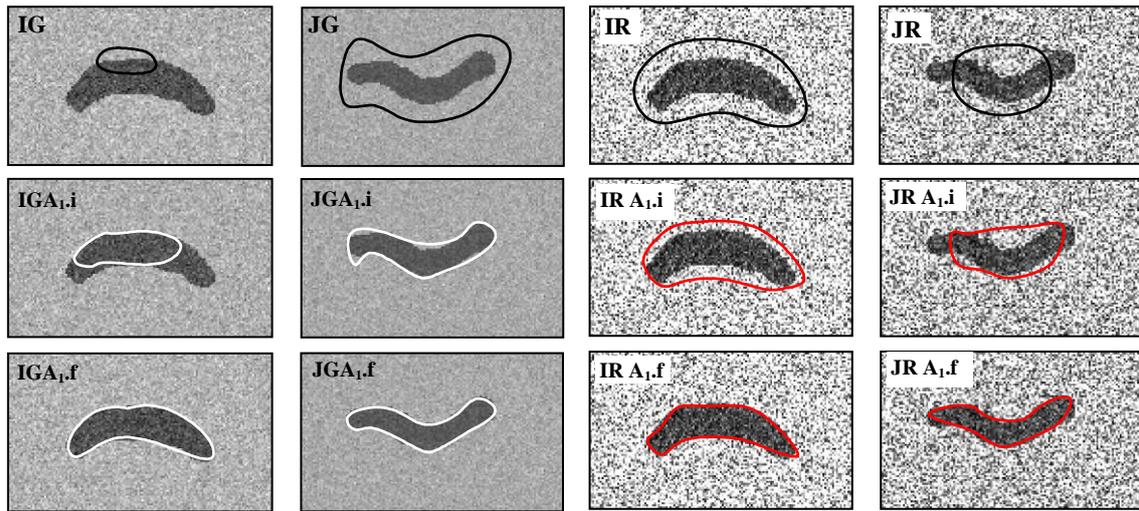


Fig. II.9 Images synthétiques avec des distributions gaussienne et de Rayleigh et résultat de la méthode d'estimation de contour de l'Algorithme 1. i: contour intermédiaire, f: contour final.

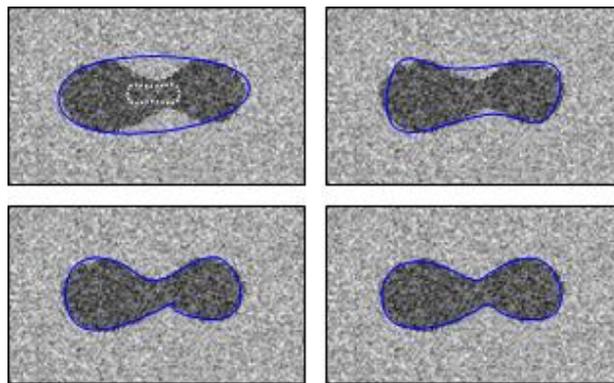


Fig. II.10 Estimation du contour de l'objet pour $k = 4, 6, 8$ et 10 pour les images de gauche à droite et de haut en bas, respectivement. La ligne en pointillés est le contour initial.

Nous avons testé Algo 1 et Algo 2 sur une image synthétique générée par une distribution gaussienne de paramètre $\{\mu_1, \sigma_1\} = \{130, 10\}$, $\{\mu_2, \sigma_2\} = \{70, 10\}$ et présentant une forme complexe. Notons à partir des résultats donnés dans Fig. II.11, qu'Algo 1 est incapable de faire adapter le contour à la forme de l'objet avec précision à cause d'une mauvaise répartition des points de contrôle régie par le schéma de déplacement de ces derniers. Cette situation entraîne un entassement de points de contrôle dans certains endroits de la courbe et un manque dans d'autres comme le montre aussi Fig. II.12. C'est pourquoi, le schéma proposé par Algo 2 peut être utilisé pour remédier à cette situation comme l'illustre Fig. II.11 et qui est confirmé par un calcul d'erreurs sur les paramètres estimés par rapport aux paramètres initiaux, où $\{\Delta\mu_1, \Delta\sigma_1\}$ et $\{\Delta\mu_2, \Delta\sigma_2\}$ sont inférieures respectivement à $\{0.5, 17\}$ et $\{0.2, 3\}$ (en %) dans les deux cas d'initialisation.

Il y a possibilité de formation de boucles dans la courbe spline pour les deux algorithmes Algo 1 et Algo 2. Pour Algo 1, ces boucles sont dues au croisement des points de jonction causé par la

configuration du (8) voisinage dans l'algorithme glouton. Par contre, pour Algo 2, l'implémentation des B-splines cubiques engendre des boucles (par exemple le cas de Fig.II.13) par le fait que ces splines sont de classe C^2 (deux fois continument dérivables aux points de jonctions). Alors, pour ce dernier cas, nous avons mis au point un test où un point de jonction est éliminé s'il forme avec ses voisins un angle ε_θ inférieur à un certain seuil.

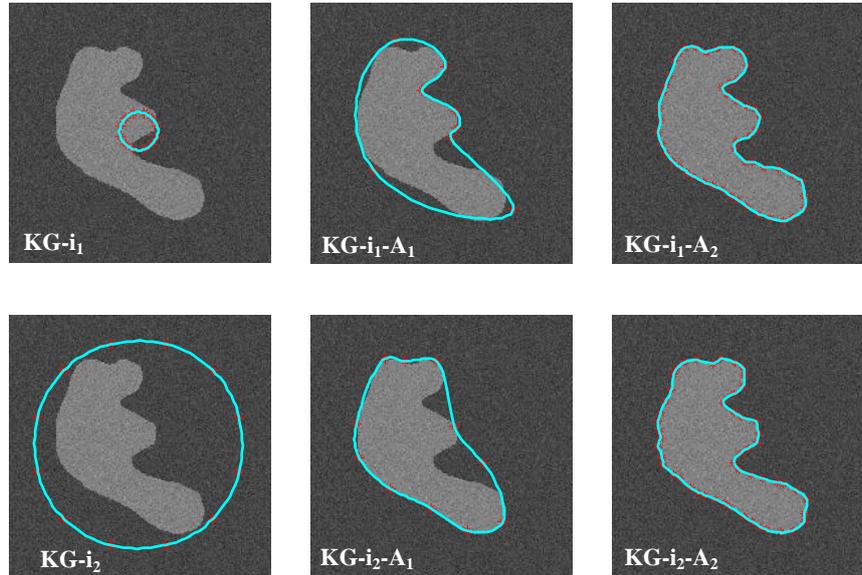


Fig. II.11 Image synthétique, contours initiaux (i_1, i_2) et estimés par Algo 1 et Algo 2

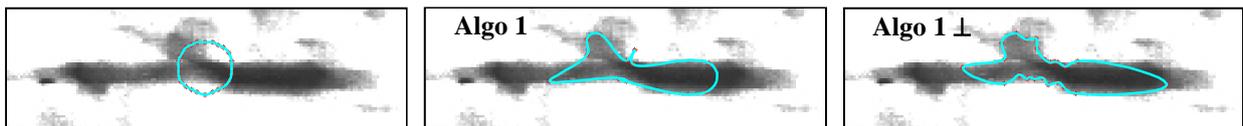


Fig. II.12 Contour initial et évolution du contour selon Algo 1 original et selon Algo 1 avec un déplacement du point de jonction selon la normale

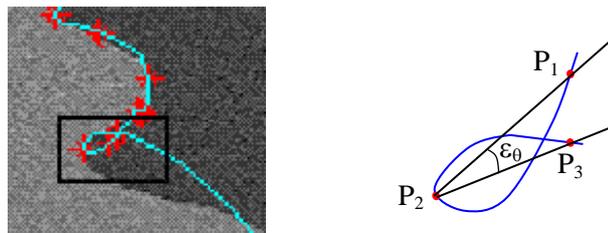


Fig. II.13 Boucle dans une B-spline

Pour comparer les résultats donnés par les deux algorithmes proposés, deux images radiographiques réelles (Im.R1 et Im.R2) représentant des défauts de soudure ont été utilisées (voir Fig. II.14). Les images binaires de référence ont été extraites manuellement par un expert radiographe dans le but de les utiliser dans le calcul des paramètres des régions du défaut et du fond. Pour montrer l'importance du choix de modèle de distribution, nous considérons ces images comme ayant une distribution de Gauss et de Rayleigh; ainsi, leurs paramètres sont calculés *a priori* (voir Table II.1). Le même contour initial a été utilisé pour les deux lois et les deux algorithmes dans le cas de Im.R2. Cependant, pour Im.R1, l'initialisation de Algo 1 par un cercle centré au milieu de l'image ne fait pas évoluer le contour jusqu'aux frontières réelles du défaut, comme il été constaté dans Fig. II.12. Ceci est du aux insuffisances de cet algorithme citées plus haut. Alors, nous avons utilisé une initialisation manuelle comme le montre l'image (Im.R1.i1) de Fig. II.14. Nous remarquons, à travers les résultats visuels du contour actif donné dans Fig. II.14 conforté par les erreurs d'estimation des paramètres donné dans Table II.1, que Algo. 2 est plus précis dans la restitution du contour du défaut par rapport à Algo. 1 d'un coté, et que le contour est mieux estimé en considérant la distribution gaussienne. En effet, dans le cas par exemple de Im.R2 utilisant la distribution gaussienne, Algo 2 démarre avec 12 points de jonctions du contour initial pour atteindre 56 points de jonction dans le contour final. Ces ajouts de points de contrôle sont donc faits dans le but d'adapter la courbe B-spline lors de son évolution aux complexités de la forme de défaut en question. En plus, l'entassement des points dans un endroit particulier de la courbe est évité grâce à l'opération de fusion. Ce qui confère à la courbe résultante une régularisation supplémentaire, mise à part celle liée à la représentation des B-spline elle-même, dans la mesure où le rééchantillonnage s'est fait d'une manière uniforme. Ce type de régularisation peut être lié aux forces élastiques données dans le premier terme de (II.2) dans le modèle de Kass et al. [63]. Dans Fig. II. 15, l'estimation du contour du défaut (Im.R3) par Algo 2 échoue complètement en considérant le modèle de Rayleigh, ce qui confirme que pour les modèles déformables probabilistes, la connaissance *a priori* de la loi statistique régissant l'image est très importante. La mauvaise performance de la segmentation, en supposant que nos images soient générées par la loi de Rayleigh, est prévisible du moment où l'image radiographique en imagerie industrielle (ou médicale) suit en général la loi normale à cause de la loi d'absorption différentielle régissant le processus de formation d'une telle image dont un aperçu est donné dans le chapitre 1. Les valeurs des différents seuils et constantes, choisis dans nos expérimentations, pour Algos 1 et 2 sont récapitulés comme suit : $\varepsilon = 10^{-6}$, $\varepsilon_1 = 10^{-6}$, $\varepsilon_2 = 10^{-6}$, $\delta_s = 1.2$, $\delta_m = 0.6$, $\varepsilon_\theta = \pi/45$, $\Delta^\perp = \pm 1$.

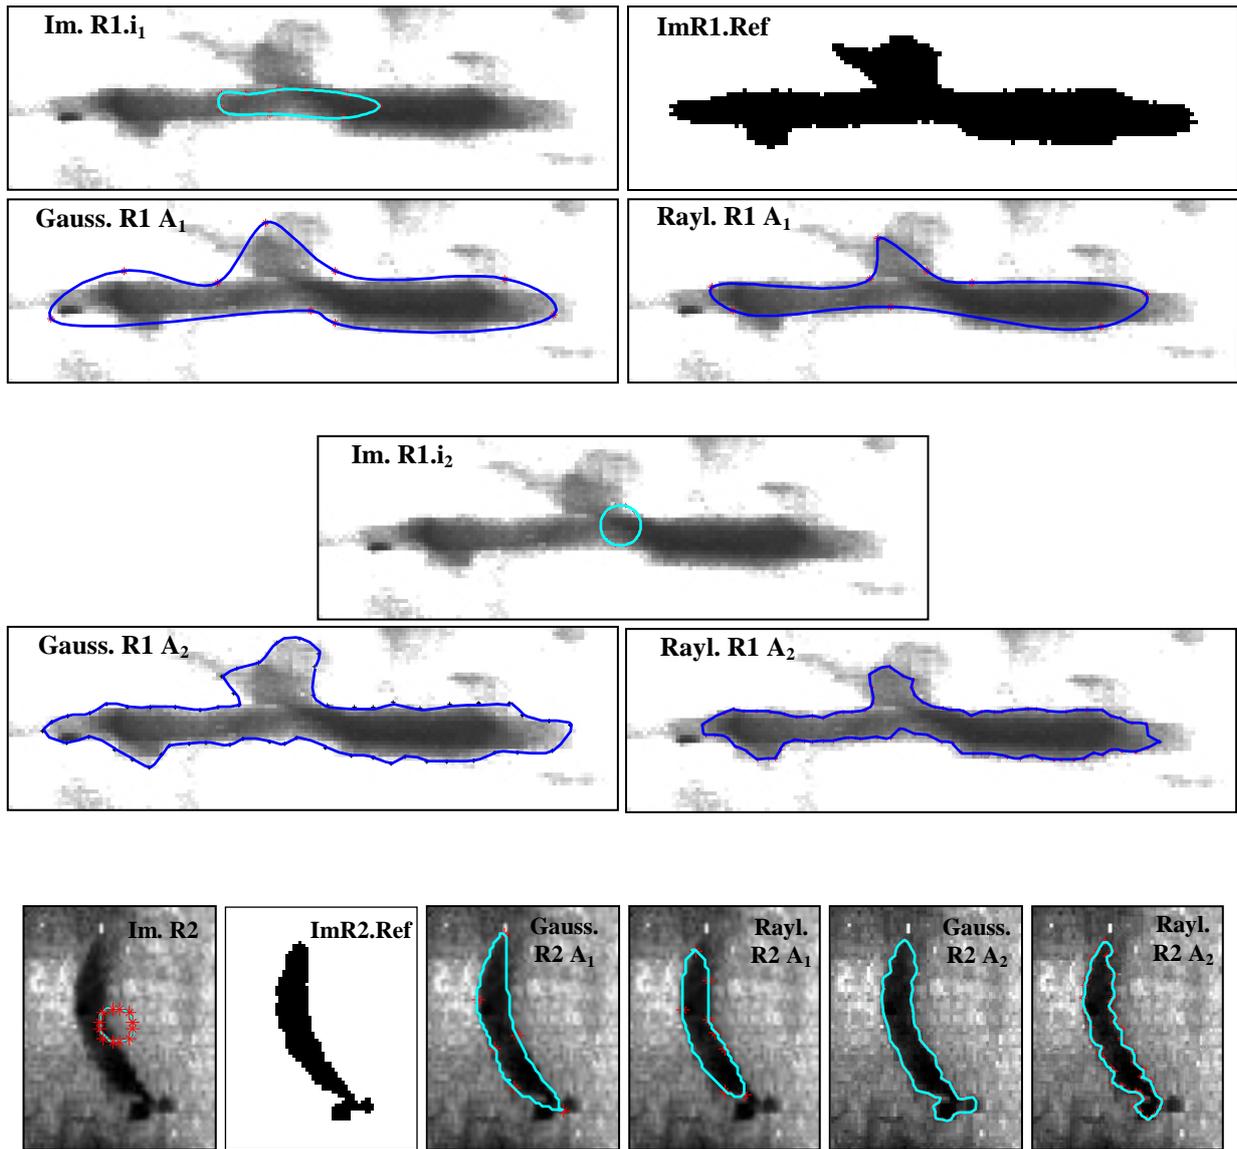


Fig. II.14 Images réelles représentant des défauts de soudure, images binaires de référence, Contours estimés par Algo. 1, resp. Algo. 2 avec les modèles de gauss et Rayleigh

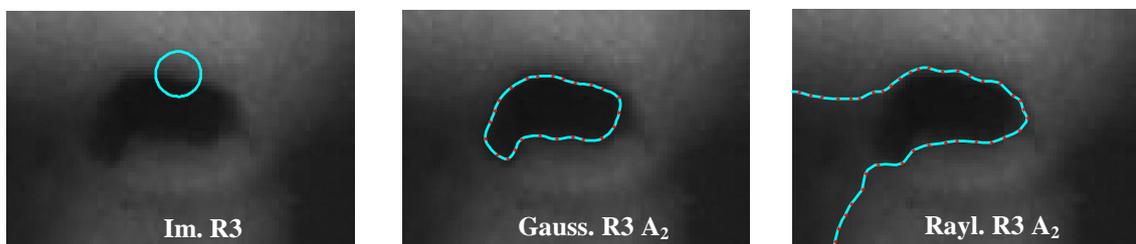


Fig. II.15 Cas d'échec du modèle de Rayleigh dans l'estimation du contour du défaut

Table 1. Paramètres des régions intérieure R_1 et extérieure R_2 pour les images réelles (Fig.II.14) avec le contour de référence et le contour estimé

		Image de référence		Algo 1		Algo 2	
		μ_1, σ_1	μ_2, σ_2	$\hat{\mu}_1, \hat{\sigma}_1$	$\hat{\mu}_2, \hat{\sigma}_2$	$\hat{\mu}_1, \hat{\sigma}_1$	$\hat{\mu}_2, \hat{\sigma}_2$
Gauss	Image 1	27.47 19.05	136.08 45.63	31.06 19.77	135.90 46.01	27.92 18.60	138.23 45.31
	Image 2	123.50 57.36	248.28 19.72	125.42 59.01	248.95 17.01	123.65 53.30	250.59 13.71
Rayleigh		ϕ_1	ϕ_2	$\hat{\phi}_1$	$\hat{\phi}_2$	$\hat{\phi}_1$	$\hat{\phi}_2$
	Image 1	23.92	101.49	20.94	100.45	22.20	101.08
	Image 2	96.29	176.12	67.11	172.51	67.98	173.54

II.8 Conclusion

Après avoir donné un état de l'art sur les contours actifs basés contour et basés région, nous avons présenté et appliqué un modèle déformable probabiliste représenté par les B-splines. En effet, une première approche (Algo 1) consiste en l'utilisation d'une paramétrisation B-spline du contour associée à une estimation statistique des régions délimitant le contour. Pour cette approche, le nombre de points de contrôle de la B-spline ne varie pas durant son évolution. Chaque point de contrôle de la B-spline parcourue dans un sens prédéfini, se déplace dans ses huit (8) voisins et le déplacement qui maximise la fonction de vraisemblance est retenu. Ce processus est itéré sur tous les points de contrôle jusqu'à ce qu'aucune déformation ne se produise, alors l'algorithme s'arrête. Cependant, il se peut qu'au cours de sa convergence, le contour reste piégé dans un minimum local ou bien ladite paramétrisation de la B-spline est incapable de s'adapter aux formes assez complexes ; ce que peut se traduire par une mauvaise segmentation. Alors, pour remédier à cette situation, une modification de l'algorithme précédent est proposée (Algo 2). Le nombre de points de contrôle est donc pris adaptatif par une règle de division/fusion selon un critère lié à la distance entre deux points de contrôle successifs. Le déplacement du point de contrôle se fait selon la normale en ce point. Les résultats de cet algorithme sur des images radiographiques de défauts de soudures, caractérisées par un mauvais contraste et un fond non uniforme et texturé, sont très prometteurs dans la mesure où les contours estimés correspondent presque parfaitement aux contours extraits par des experts en radiographie. Cependant, le choix du modèle du processus de génération de l'image est très important et qui suit loi gaussienne dans le cas de notre application.

Chapitre 3

Méthodes de seuillage d'images et post-traitement

III.1 Introduction

Les images des films radiographiques contiennent des défauts de soudure placés sur le fond avec différentes intensités. Pour de telles images, l'intensité ou le niveau de gris est un paramètre distinctif qui peut être utilisé pour extraire les défauts du fond de l'image du film [14]. Par conséquent, une technique de seuillage peut être un puissant candidat pour une segmentation efficace. Le seuillage est le processus qui divise les pixels dans l'image en deux classes : l'objet et le fond, basées sur la relation entre la valeur du niveau de gris d'un pixel et un paramètre appelé le seuil. En raison de leur efficacité d'exécution et leur simplicité dans la théorie, les techniques de seuillage ont été étudiées intensivement, et un grand nombre de méthodes ont été publiées [120,121]. Ces méthodes peuvent être divisées en deux catégories : les méthodes globales ou les méthodes basées sur l'histogramme et les méthodes locales. Les méthodes globales calculent une seule valeur du seuil pour l'image entière, où les pixels ayant une valeur de niveau gris inférieure à la valeur du seuil sont affectés à une classe, et les autres pixels sont affectés à l'autre classe. Les méthodes locales, d'autre part, calculent une valeur du seuil pour chaque pixel sur la base de l'information contenue dans le voisinage local du pixel. Trouver la valeur correcte du seuil pour segmenter une image en régions d'objet et de fond souhaitables, reste une étape très importante dans le système de traitement d'image. En outre, nous sommes toujours intéressés à chercher un certain algorithme universel pour obtenir la valeur du seuil automatiquement.

Dans ce chapitre, les paramètres statistiques basés sur les histogrammes à une et deux dimensions, la moyenne et la variance locales, mesurés sur les images considérées seront utilisées pour distinguer, par rapport au fond, le meilleur objet représentant le plus précisément possible la région du défaut de soudure. Nous implémentons quatre méthodes de seuillage basées sur l'histogramme des niveaux de gris sur les images des films radiographiques des joints soudés. Les deux premières méthodes (Otsu et Kittler) sont basées sur la sélection du seuil par un critère statistique. Une autre méthode (Kapur) est basée sur la mesure d'entropie. La dernière méthode implémentée dans cette section est basée sur la préservation des moments entre l'image en niveaux de gris et sa version binaire. Par la suite, on donnera un aperçu sur les matrices de cooccurrence et leur application dans le seuillage via les entropies locale, jointe et relative. Des méthodes locales adaptatives de Niblack et Sauvola basées sur les propriétés statistiques des niveaux de gris prises dans le voisinage de chaque pixel de l'image seront implémentées.

Dans des applications pratiques de seuillage, si l'image à binariser est complexe et l'algorithme est entièrement automatique, l'erreur est inévitable. La disparité entre l'image réellement binarisée et l'image correctement ou idéalement binarisée (image binaire de référence) qui est

le meilleur résultat prévu peut être employée pour évaluer la performance des algorithmes [122]. Dans le cas des images radiographiques des joints soudés, le seuillage automatique d'images rencontre des difficultés parce que les niveaux de gris de l'objet (défaut de soudure) et du fond possèdent des distributions qui se chevauchent substantiellement, présentant souvent une distribution à un seul mode. En conséquence, les pixels mal classifiés et les déformations de forme de l'objet peuvent compromettre les résultats de l'interprétation du film radiographique. Pour cette raison, les critères pour évaluer des algorithmes de seuillage doivent prendre en considération à la fois le bruit inclus dans la topographie de segmentation ainsi que la déformation de forme des défauts de soudure. Les méthodes d'évaluation du seuillage choisies sont: erreur de classification (ME), erreur relative de l'aire d'objet (RAE), la non uniformité (irrégularité) de région (NU), et la mesure de déformation de forme (SM). Nous avons adapté ces mesures de performance de sorte que leurs résultats varient de 0 pour une segmentation totalement correcte à 1 pour une segmentation totalement erronée. Après seuillage, l'image binarisée contient des informations superfétatoires qu'il convient d'éviter, ou masquées qu'il faut révéler et ce, quelque soit la méthode de seuillage employée. Un post-traitement basé sur la morphologie mathématique peut être appliqué dans le but d'extraire une seule région connexe représentant le défaut de soudure.

Dans la section 2, nous implémentons quatre méthodes de seuillage basées sur l'histogramme des niveaux de gris sur les images des films radiographiques des joints soudés. Les deux premières méthodes (Otsu et Kittler) sont basées sur la sélection du seuil par un critère statistique. Une autre méthode (Kapur) est basée sur la mesure d'entropie. La dernière méthode implémentée dans cette section est basée sur la préservation des moments entre l'image en niveaux de gris et sa version binaire. La section 3 sera consacrée aux matrices de cooccurrence et leur application dans le seuillage via les entropies locale, jointe et relative. Dans la section 4, les méthodes locales adaptatives de Niblack et Sauvola basées sur les propriétés statistiques des niveaux de gris prises dans le voisinage de chaque pixel de l'image sont implémentées. Dans la section 5, nous présentons la méthodologie de comparaison et les critères de performance utilisés pour l'évaluation du seuillage. La section 6 se rapportera à l'application d'un post-traitement aux images binarisées. Les résultats obtenus à partir des images réelles de défauts de soudure et leurs commentaires sont donnés dans la section 7. Finalement, la section 8 illustre les principales conclusions.

III.2 Seuillage basé sur l'histogramme 1-D

III.2.1 Définitions

Soient les pixels de l'image représentés par L niveaux de gris ($0, 1, 2, \dots, L-1$). Le nombre de pixels d'un niveau de gris i est noté par n_i et le nombre total de pixel est noté par N . Pour simplifier, l'histogramme des niveaux de gris est normalisé et considéré comme une densité de distribution :

$$p_i = n_i / N, \quad p_i \geq 0, \quad \sum_{i=0}^{L-1} p_i = 1 \quad (\text{III.1})$$

Supposons qu'on divise les pixels en deux classes C_0 et C_1 (fond et objet) par une valeur de seuil au niveau de gris k ; C_0 représente les pixels avec les niveaux de gris $[0, 1, \dots, k]$ et C_1 représente les pixels avec les niveaux de gris $[k+1, \dots, L-1]$.

Les probabilités d'apparition des classes sont données par:

$$\omega_0 = \Pr(C_0) = \sum_{i=0}^k p_i = \omega(k) \quad (\text{III.2})$$

$$\omega_1 = \Pr(C_1) = \sum_{i=k+1}^{L-1} p_i = 1 - \omega(k) \quad (\text{III.3})$$

Les moments cumulés d'ordre 1 (moyenne) et d'ordre 2 (variance) des classes sont définis comme suit :

$$\mu_0 = \sum_{i=0}^k i \Pr(i / C_0) = \sum_{i=0}^k i p_i / \omega_0 = \mu(k) / \omega(k) \quad (\text{III.4})$$

$$\mu_1 = \sum_{i=k+1}^{L-1} i \Pr(i / C_1) = \sum_{i=k+1}^{L-1} i p_i / \omega_1 = \frac{\mu_T - \mu(k)}{1 - \omega(k)} \quad (\text{III.5})$$

$$\sigma_0^2 = \sum_{i=0}^k (i - \mu_0)^2 \Pr(i / C_0) = \sum_{i=0}^k (i - \mu_0)^2 p_i / \omega_0 \quad (\text{III.6})$$

$$\sigma_1^2 = \sum_{i=k+1}^{L-1} (i - \mu_1)^2 \Pr(i / C_1) = \sum_{i=k+1}^{L-1} (i - \mu_1)^2 p_i / \omega_1 \quad (\text{III.7})$$

$$\text{avec} \quad \omega(k) = \sum_{i=0}^k p_i \quad (\text{III.8})$$

$$\mu(k) = \sum_{i=0}^k i p_i \quad (\text{III.9})$$

$$\mu_T = \sum_{i=0}^{L-1} i p_i \quad (\text{III.10})$$

$$\text{et} \quad \sigma_T^2 = \sum_{i=0}^{L-1} (i - \mu_T)^2 p_i \quad (\text{III.11})$$

où μ_T et σ_T^2 sont respectivement la moyenne et la variance totales de l'image.

On peut vérifier aisément la relation suivante pour n'importe quel choix de k :

$$\omega_0\mu_0 + \omega_1\mu_1 = \mu_T, \quad \omega_0 + \omega_1 = 1 \quad (\text{III.12})$$

III.2.2. Méthode de la variance d'Otsu

Dans le but d'évaluer la performance d'un seuil (au niveau de gris k), Otsu [123] a introduit les critères de mesure de la séparabilité des classes, utilisés dans l'analyse discriminante, comme suit :

$$\lambda = \sigma_B^2 / \sigma_W^2, \quad \kappa = \sigma_T^2 / \sigma_W^2, \quad \eta = \sigma_B^2 / \sigma_T^2 \quad (\text{III.13})$$

$$\text{où} \quad \sigma_W^2 = \omega_0\sigma_0^2 + \omega_1\sigma_1^2 \quad (\text{III.14})$$

$$\text{et} \quad \sigma_B^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2 = \omega_0\omega_1(\mu_1 - \mu_0)^2 \quad (\text{III.15})$$

sont respectivement, la variance intraclasse et la variance interclasse.

Nous avons donc à résoudre un problème d'optimisation pour trouver le seuil qui maximise l'une des fonctions objectives définies dans (III.13).

Les critères λ , κ et η sont équivalents les uns aux autres en terme de maximisation pour un seuil k , parce qu'ils sont liés par les relations : par exemple, $\kappa = \lambda + 1$ et $\eta = \lambda / (\lambda + 1)$ en terme de λ , et qui découlent de la relation de base suivante :

$$\sigma_T^2 = \sigma_W^2 + \sigma_B^2 \quad (\text{III.16})$$

On remarque que σ_W^2 et σ_B^2 sont fonctions du seuil de niveau k , mais σ_T^2 est indépendant de k . On remarque aussi que σ_W^2 s'exprime en fonction des statistiques de second ordre (variances), tandis que σ_B^2 s'exprime en fonction des statistiques de premier ordre (moyennes). C'est pourquoi, η est adopté comme critère de séparabilité de classes pour sa simplicité de calcul.

Le seuil optimal k_{Ots}^* qui maximise η ou, d'une manière équivalente, maximise σ_B^2 , est donné comme suit :

$$k_{Ots}^* = \arg \max_k \{ \sigma_B^2(k) \} \quad (\text{III.17})$$

où, en utilisant (III. 2)–(III.5) et (III. 15), $\sigma_B^2(k)$ est défini comme suit :

$$\sigma_B^2(k) = \frac{[\mu_T \omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (\text{III.18})$$

III.2.3. Algorithme de minimisation d'erreur de Kittler et Illingworth

Dans la méthode à erreur minimale de Kittler et Illingworth [124], l'histogramme des niveaux de gris est perçu comme une estimation de la fonction de densité de probabilité d'un mélange de populations. Nous supposons que chaque composant $\Pr(i/C_j)$, $j = 0, 1$, du mélange suit une distribution normale de moyenne μ_j , d'écart type σ_j et de probabilité a priori ω_j , définis dans §III.2.1., de sorte que

$$p_i = \sum_{j=0}^1 \omega_j \Pr(i/C_j) \quad (\text{III.19})$$

où

$$\Pr(i/C_j) = \frac{1}{\sqrt{2\pi}\sigma_j} e^{-(i-\mu_j)^2/2\sigma_j^2} \quad (\text{III.20})$$

Etant donné $\Pr(i/C_j)$ et ω_j , il existe un niveau de gris τ pour lequel les niveaux de gris i satisfont

$$\begin{cases} \omega_0 \Pr(i/C_0) > \omega_1 \Pr(i/C_1) & \text{si } i \leq \tau \\ \omega_0 \Pr(i/C_0) < \omega_1 \Pr(i/C_1) & \text{si } i > \tau \end{cases} \quad (\text{III.21})$$

Le seuil τ est le seuil d'erreur minimum de Bayes à laquelle l'image peut être binarisée.

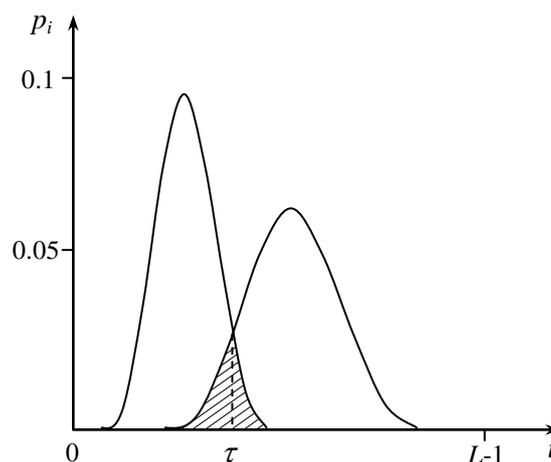


Fig. III.1 Erreur de binarisation (surface hachurée) pour un mélange de deux gaussiennes

Prenant le logarithme népérien des deux coté dans (III.21), cette condition peut être reformulée comme

$$\begin{cases} \frac{(i - \mu_0)^2}{\sigma_0^2} + \ln \sigma_0^2 - 2 \ln \omega_0 < \frac{(i - \mu_1)^2}{\sigma_1^2} + \ln \sigma_1^2 - 2 \ln \omega_1 & \text{si } i \leq \tau \\ \frac{(i - \mu_0)^2}{\sigma_0^2} + \ln \sigma_0^2 - 2 \ln \omega_0 > \frac{(i - \mu_1)^2}{\sigma_1^2} + \ln \sigma_1^2 - 2 \ln \omega_1 & \text{si } i > \tau \end{cases} \quad (\text{III.22})$$

Le problème de la sélection du seuil à erreur minimale repose sur la détermination de τ .

Le seuil d'erreur minimale peut être obtenu par la résolution de l'équation quadratique définie en égalisant les deux cotés droit et gauche de (III.22).

Puisque μ_j , σ_j et ω_j sont rarement connus, ils doivent être estimés en utilisant des techniques appropriées et chères en termes de calcul. Kittler et Illingworth proposent une technique plus simple pour obtenir ces estimations. Supposons qu'on divise l'histogramme à un seuil arbitraire k , alors nous pouvons modéliser les deux populations résultantes par une densité de probabilité normale $Pr(i/C_j, k)$ avec $\mu_j(k)$, $\sigma_j(k)$ et $\omega_j(k)$ comme paramètres dont les définitions peuvent être aisément déduites de § III.2.1.

En utilisant les modèles $Pr(i/C_j, k)$, $j = 0$ si $i \leq k$ et $j = 1$ ailleurs, la probabilité conditionnelle $Pr(i/C_j, k)$, d'un niveau de gris i , étant correctement classifié, est donnée par

$$e(i, k) = \frac{\Pr(i/C_j, k) \omega_j(k)}{p_i} \quad (\text{III.23})$$

Puisque p_i est indépendant de j et k , il peut être sans risque ignoré dans l'équation ci-dessus. En outre, en ajoutant le logarithme des deux côtés dans (III.23), la valeur de maximum ne variera pas puisque le logarithme est une fonction strictement croissante. Pour des raisons de simplification, nous multiplions le résultat par -2 , nous aurons

$$\varepsilon(i, k) = \left(\frac{i - \mu_j(k)}{\sigma_j(k)} \right)^2 + 2 \ln \sigma_j(k) - 2 \ln \omega_j(k) \quad (\text{III.24})$$

où $\varepsilon(i, k) = \ln(e(i, k))$.

La performance moyenne pour l'image totale peut être caractérisée par le critère suivant

$$J(k) = \sum_i p_i \varepsilon(i, k) \quad (\text{III.25})$$

Pour un seuil donné k , ce critère reflète indirectement la surface de chevauchement entre les modèles gaussiens des populations de l'objet et du fond, comme l'illustre Fig. III.1.

Comme le seuil k varie, les modèles de distribution des populations change. Plus est meilleur l'ajustement entre les données et les modèles, plus est petit le chevauchement entre les fonctions de densité et par conséquent plus est petite l'erreur de classification.

La valeur du seuil k , produisant la valeur la plus basse du critère $J(\varepsilon, k)$, donnera le modèle le plus convenable et donc le seuil à erreur minimale. En résumé, le problème de la sélection du seuil à erreur minimale peut être exprimé comme un problème de minimisation du critère $J(k)$, i.e.

$$J(\tau) = \min_k J(k) \quad (\text{III.26})$$

Exprimons le critère $J(k)$ comme

$$J(k) = \sum_{i=0}^k p_i \left(\left(\frac{i - \mu_0}{\sigma_0} \right)^2 + 2 \ln \sigma_0 - 2 \ln \omega_0 \right) + \sum_{i=k+1}^{L-1} p_i \left(\left(\frac{i - \mu_1}{\sigma_1} \right)^2 + 2 \ln \sigma_1 - 2 \ln \omega_1 \right) \quad (\text{III.27})$$

qui est réduit à

$$J(k) = 1 + 2(\omega_0 \ln \sigma_0 + \omega_1 \ln \sigma_1) - 2(\omega_0 \ln \omega_0 + \omega_1 \ln \omega_1) \quad (\text{III.28})$$

Le seuil optimal est donné par

$$k_{\text{Kit}}^* = \arg \min_k \{J(k)\} \quad (\text{III.29})$$

III.2.4 La méthode de seuillage de Kapur basée sur l'entropie

III.2.4.1 Mesure de l'information

Lorsque nous connaissons le résultat d'une expérience, nous pouvons aussi être intéressés par la quantité d'information qui caractérise ce résultat. Nous voudrions donc mesurer la quantité d'information que nous recevons lorsqu'une expérience a eu lieu et que nous connaissons le résultat. Une information est considérée comme telle si et seulement si elle élimine une certaine incertitude, d'où le lien très étroit entre information et incertitude. On peut dire que, plus l'incertitude est grande au début d'une expérience, plus l'information que l'on obtient à la fin est grande. Du fait que l'information supprime une incertitude, la mesure d'incertitude peut être aussi utilisée pour quantifier l'information obtenue [125]. Dans ce cas, le sens de variation de l'incertitude est opposé au sens de variation de l'information.

Soit x un évènement réalisé avec une certaine probabilité p . On mesure son improbabilité ou incertitude par $f(p)$, $f(\cdot)$ étant une fonction décroissante convenablement choisie. La quantité d'information associée à l'évènement x est donc :

$$I(x) = f(p) \quad (\text{III.30})$$

Pour choisir la fonction $f(\cdot)$, il est raisonnable d'admettre que la quantité d'information fournie par la réalisation conjointe de deux évènements x et y statistiquement indépendants doit être

égale à la somme des quantités d'information fournies par les réalisations de x et y pris séparément. On souhaite donc avoir :

$$I(x_1, x_2) = I(x_1) + I(x_2) \quad (\text{III.31})$$

Ceci implique pour la fonction $f(\cdot)$:

$$f(p_1 p_2) = f(p_1) + f(p_2) \quad (\text{III.32})$$

où p_1 et p_2 sont les probabilités de réalisation de x_1 et x_2 , respectivement. En effet, la probabilité de réalisation conjointe de x_1 et x_2 est le produit $p_1 p_2$ de leurs probabilités. La fonction continue qui, à un argument formé d'un produit, associe la somme des fonctions ayant chacun de ses termes pour argument est la fonction logarithme.

On est par conséquent conduit à choisir $I(x) = \lambda \log(p)$ avec $\lambda < 0$, pour assurer la décroissance par rapport à p . Ce choix entraîne aussi que $I(x) = 0$ si $p = 1$, c'est-à-dire que l'occurrence d'un évènement certain ne peut fournir aucune information, et contrairement $I(x) = \infty$ si $p = 0$, c'est-à-dire un évènement impossible ouvre la voie à un nombre infini d'informations, en conformité avec ce qui a été cité plus haut.

Le choix de λ dépendra du choix de l'unité de mesure de l'information. Usuellement, l'unité de mesure utilisée est le bit (binary unit) qui est égal à la quantité d'information fournie par le choix d'une alternative parmi deux équiprobables.

Cela signifie que si x est choisi dans l'espace des épreuves $\{0,1\}$ muni d'une loi uniforme (i.e. $\Pr(x=0) = \Pr(x=1) = 1/2$), alors la quantité d'information fournie par la réalisation de l'évènement $x = 0$ (ou $x = 1$) est alors de 1 bit. On a

$$I(x=0) = \lambda \log \Pr(x=0) = \lambda \log \frac{1}{2} = -\lambda \log 2 = 1 \quad (\text{III.33})$$

donc $\lambda = -1/\log 2$ ce qui revient à choisir le logarithme en base 2 pour la définition de $I(x)$:

$$I(x) = -\log_2 p \quad (\text{III.34})$$

III.2.4.2 Entropie et seuillage

Le concept de l'entropie introduit par Shannon en 1948 est le fondement central de la théorie de l'information parfois désignée comme mesure d'incertitude. L'entropie d'une variable aléatoire est définie en termes de sa distribution de probabilité et peut s'avérer une bonne mesure d'aspect aléatoire ou d'incertitude.

Soit une source d'information X ayant N symboles notée $\{x_i\}_{i=1}^N$ et soit p_i la probabilité d'apparition de chaque symbole x_i avec $\sum_{i=1}^N p_i = 1$. Pour chaque symbole x_i de la source, nous

avons défini dans le paragraphe précédent son information propre comme $I(x_i) = -\log_2 p_i$. On définit donc l'entropie associée à la source X comme la quantité d'information propre moyenne sur les N symboles de la sources, en d'autres termes, elle est l'espérance mathématique (notée $E\{\cdot\}$) de l'information propre fournie par l'observation de chacun des symboles de la source $\{x_i\}_{i=1}^N$.

$$H(X) = E\{I(X)\} = \sum_{i=0}^{N-1} p_i I(x_i) = -\sum_{i=1}^N p_i \log_2 p_i \quad (\text{III.35})$$

On présente ci-après quelques propriétés associées à la fonction entropie.

1. $H(X) \geq 0$
2. $H(X) = 0$ si $\exists i / p_i = 1$
3. $H(X) \leq \underbrace{H(1/N, 1/N, \dots, 1/N)}_{N \text{ fois}}$
4. $H(X, Y) = H(X) + H(Y)$ si X et Y sont deux expériences indépendantes

Remarque : Dans les problèmes d'optimisation en général et de traitement d'image en particulier, où nous sommes amenés à dériver, le choix du logarithme népérien dans l'expression de l'entropie est plus adéquat. Dans ce cas l'entropie est mesurée en nats.

Comme une image peut être perçue comme une source d'information avec un vecteur de probabilité décrit par l'histogramme des niveaux de gris de l'image, l'entropie de l'histogramme peut être utilisée pour représenter un certain niveau d'information contenue dans l'image.

Pour une image définie dans § III.2.1., et d'après (III.35), son entropie est donnée par :

$$H(p_0, p_1, \dots, p_{L-1}) = -\sum_{i=0}^{L-1} p_i \ln p_i \quad (\text{III.36})$$

Kapur et al. [126] ont exploité ce concept pour l'appliquer dans les méthodes de seuillage de l'image, et ce en maximisant la qualité de l'information retenue.

Soit p_0, p_1, \dots, p_{L-1} la distribution de probabilité des niveaux de gris. On obtient à partir de cette distribution deux autres distributions, une liée à l'objet C_0 et définie pour les valeurs de niveaux de gris de 0 à k et l'autre liée au fond C_1 définie pour les valeurs de $k+1$ à $L-1$. Les deux distributions sont :

$$C_0: \frac{p_0}{\omega(k)}, \frac{p_1}{\omega(k)}, \dots, \frac{p_k}{\omega(k)} \quad (\text{III.37})$$

$$C_1: \frac{p_{k+1}}{1-\omega(k)}, \frac{p_{k+2}}{1-\omega(k)}, \dots, \frac{p_{L-1}}{1-\omega(k)} \quad (\text{III.38})$$

Les entropies associées avec chacune des distributions sont comme suit :

$$\begin{aligned}
 H_0(k) &= -\sum_{i=0}^k \frac{p_i}{\omega(k)} \ln \frac{p_i}{\omega(k)} \\
 &= -\frac{1}{\omega(k)} \left[\sum_{i=1}^k p_i \ln p_i - \omega(k) \ln \omega(k) \right] \\
 &= \ln \omega(k) + \frac{H_k}{\omega(k)}
 \end{aligned} \tag{III.39}$$

où

$$H_k = H(p_0, p_1, \dots, p_k) = -\sum_{i=0}^k p_i \ln p_i \text{ pour } k = 0, 1, \dots, L-1.$$

D'une manière similaire

$$\begin{aligned}
 H_1(k) &= -\sum_{i=k+1}^{L-1} \frac{p_i}{1-\omega(k)} \ln \frac{p_i}{1-\omega(k)} \\
 &= -\frac{1}{1-\omega(k)} \left[\sum_{i=k+1}^{L-1} p_i \ln p_i - (1-\omega(k)) \ln(1-\omega(k)) \right] \\
 &= \ln(1-\omega(k)) + \frac{H_{L-1} - H_k}{1-\omega(k)}
 \end{aligned} \tag{III.40}$$

où

$$H_{L-1} = H(p_0, p_1, \dots, p_{L-1}) = -\sum_{i=0}^{L-1} p_i \ln p_i$$

On définit la somme de $H_0(k)$ et $H_1(k)$ par $\psi(k)$. Par conséquent, on obtient à partir de (III.39) et (III.40)

$$\psi(k) = \ln[\omega(k)(1-\omega(k))] + \frac{H_k}{\omega(k)} + \frac{H_{L-1} - H_k}{1-\omega(k)} \tag{III.41}$$

On maximise $\psi(k)$ pour obtenir l'information maximale entre l'objet et le fond dans l'image. La valeur k qui maximise $\psi(k)$ est la valeur du seuil. On a ainsi :

$$k_{Kap}^* = \arg \max_k \{\psi(k)\} \tag{III.42}$$

III.2.5 Méthode de seuillage par préservation des moments de Tsai

Etant donné une image en niveaux de gris f dont le niveau de gris du pixel (x, y) est $f(x, y)$, le moment d'ordre j de f est donné par

$$m_j = \frac{1}{N} \sum_x \sum_y f^j(x, y), \quad j = 0, 1, 2, 3, \dots \tag{III.43}$$

Les moments peuvent être également calculés à partir de l'histogramme de f comme suit :

$$m_j = \frac{1}{N} \sum_{i=0}^{L-1} n_i i^j = \sum_{i=0}^{L-1} p_i i^j, \quad j = 0, 1, 2, 3, \dots \quad (\text{III.44})$$

où, i , L , N , n_i et p_i sont définis dans § III.2.1. On déduit de (III.44) que $m_0 = 1$.

Soit O un opérateur, appliqué à l'image d'entrée f , et g l'image de sortie. Si le $j^{\text{ème}}$ moment de g est mis égal à celui de f , alors on dit que O préserve le $j^{\text{ème}}$ moment des données d'entrée dans les données de sortie. Par définition, nous voyons que si un opérateur préserve plus de moments, alors il y aura plus d'information de l'image d'entrée qui sera sauvegardée dans l'image de sortie. Supposons qu'on souhaite effectuer le seuillage de f en deux niveaux i_0 et i_1 avec $i_0 < i_1$. Les proportions des pixels aux niveaux i_0 et i_1 sont respectivement ω_0 et ω_1 . L'algorithme de Tsai [127] choisit la valeur du seuil de telle manière que si tous les pixels de f aux niveaux de gris inférieurs au seuil sont remplacés par la valeur i_0 et tous les pixels de f aux niveaux de gris supérieurs au seuil sont remplacés par la valeur i_1 , alors les trois premiers moments de l'image f sont préservés dans l'image binaire résultante g . Puis, en préservant les trois premiers moments dans, à la fois, l'image en niveaux de gris originale et l'image idéale binarisée, un ensemble de quatre équations peut être déduit comme suit :

$$\begin{cases} m_0 = \omega_0 i_0^0 + \omega_1 i_1^0 \\ m_1 = \omega_0 i_0^1 + \omega_1 i_1^1 \\ m_2 = \omega_0 i_0^2 + \omega_1 i_1^2 \\ m_3 = \omega_0 i_0^3 + \omega_1 i_1^3 \end{cases} \quad (\text{III.45})$$

Ainsi, en préservant les moments dans les versions originale et binaire de l'image et en utilisant l'égalité $\omega_0 + \omega_1 = 1 = m_0$, nous avons un ensemble de quatre équations qui, dans le cas binaire, sont résolues par:

$$\begin{cases} i_0 = (1/2) \left[-c_1 - (c_1^2 - 4c_0)^{1/2} \right] \\ i_1 = (1/2) \left[-c_1 + (c_1^2 - 4c_0)^{1/2} \right] \end{cases} \quad (\text{III.46})$$

$$\text{où } c_d = \begin{vmatrix} m_0 & m_1 \\ m_1 & m_2 \end{vmatrix}, \quad c_0 = \frac{1}{c_d} \begin{vmatrix} -m_2 & m_1 \\ -m_3 & m_2 \end{vmatrix}, \quad c_1 = \frac{1}{c_d} \begin{vmatrix} m_0 & -m_2 \\ m_1 & -m_3 \end{vmatrix},$$

$$\begin{cases} \omega_0 = (1/\omega_d) \begin{vmatrix} 1 & 1 \\ m_1 & i_1 \end{vmatrix} \\ \omega_1 = 1 - \omega_0 \end{cases} \quad (\text{III.47})$$

$$\text{où } \omega_d = \begin{vmatrix} 1 & 1 \\ i_0 & i_1 \end{vmatrix}$$

Posons ω_0 calculé dans (III.47) égal à ω_{0_Tsa} . En pratique, il ne peut y avoir une valeur discrète du niveau de gris k qui donnerait le résultat exact $\omega_0(k) = \omega_{0_Tsa}(k)$, $\omega_0(k)$ étant donné dans § III.2.1. C'est pourquoi, le seuil optimal k_{Tsa}^* peut être choisi de la manière suivante

$$k_{Tsa}^* = \arg \min_k \left| \omega_0(k) - \omega_{0_Tsa}(k) \right| \quad (\text{III.48})$$

III.3 Le seuillage basé sur l'histogramme 2-D

III.3.1 Matrice de cooccurrence et quadrants

La matrice de cooccurrence est la matrice de transition générée par les changements d'intensité des pixels, qui décrit toutes les transitions d'intensité d'un niveau de gris i à un niveau de gris j . Ainsi, la matrice de cooccurrence est un histogramme à deux dimensions (2-D) mettant en évidence les paires de pixels séparées par un certain vecteur spatial \vec{d} dont les coordonnées cartésiennes sont Δx et Δy avec $\Delta x = d \sin \theta$, $\Delta y = d \cos \theta$ où d (distance) et θ (orientation) sont leurs coordonnées polaires. Soit une image digitale I de taille $P \times Q$ avec L niveaux de gris $G = \{0, 1, 2, \dots, L-1\}$ et soient deux pixels (x, y) et $(x + \Delta x, y + \Delta y)$ de I avec des niveaux de gris i et j , respectivement, la matrice de cooccurrence $C_{d,\theta}$ est définie comme $C_{d,\theta} = [c_{ij}]^{L \times L}$ où :

$$c_{ij} = \sum_{x=1}^P \sum_{y=1}^Q \delta(x, y) \quad (\text{III.49})$$

avec

$$\delta(x, y) = \begin{cases} 1 & \text{si } I(x, y) = i, I(x + \Delta x, y + \Delta y) = j \\ 0 & \text{ailleurs} \end{cases}$$

La probabilité de cooccurrence p_{ij} de niveau de gris i et j peut être exprimée comme suit:

$$p_{ij} = \frac{c_{ij}}{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} c_{ij}} \quad (\text{III.50})$$

On a alors $0 \leq p_{ij} < 1$. Soit k ($k \in G$) un seuil qui divise la matrice de cooccurrence en quatre quadrants A, B, C et D , illustrés dans Fig. III.2. Pal et al. [128] ont séparé les quatre quadrants en deux types. L'un représente les objets et le fond qui correspondent respectivement aux quadrants A et C . L'autre représente les transitions à travers les frontières des objets et du fond et qui correspond aux quadrants B et D .

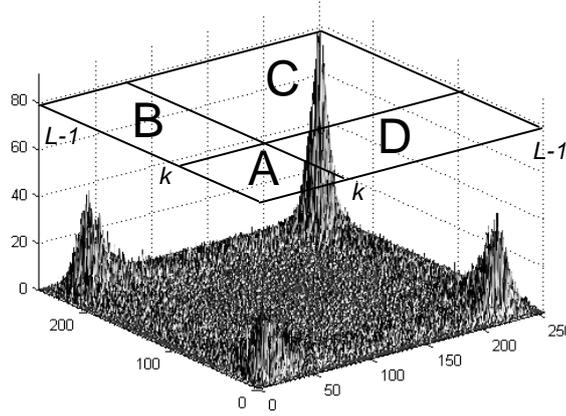


Fig. III.2 Les quadrants de la matrice de cooccurrence

Les probabilités associées à chaque quadrant sont définies comme suit [129]:

$$P_A(k) = \sum_{i=0}^k \sum_{j=0}^k p_{ij} \quad (\text{III.51})$$

$$P_B(k) = \sum_{i=0}^k \sum_{j=k+1}^{L-1} p_{ij} \quad (\text{III.52})$$

$$P_C(k) = \sum_{i=k+1}^{L-1} \sum_{j=k+1}^{L-1} p_{ij} \quad (\text{III.53})$$

$$P_D(k) = \sum_{i=k+1}^{L-1} \sum_{j=0}^k p_{ij} \quad (\text{III.54})$$

En normalisant les probabilités à l'intérieur de chaque quadrant, nous obtenons:

$$p_{ij}^A = \frac{p_{ij}}{P_A} = \frac{c_{ij} / \left(\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} c_{ij} \right)}{\sum_{i=0}^k \sum_{j=0}^k c_{ij} / \left(\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} c_{ij} \right)} = \frac{c_{ij}}{\sum_{i=0}^k \sum_{j=0}^k c_{ij}} \quad 0 \leq i, j \leq k \quad (\text{III.55})$$

$$p_{ij}^B = \frac{p_{ij}}{P_B} = \frac{c_{ij}}{\sum_{i=0}^k \sum_{j=k+1}^{L-1} c_{ij}} \quad 0 \leq i \leq k, k+1 \leq j \leq L-1 \quad (\text{III.56})$$

$$p_{ij}^C = \frac{p_{ij}}{P_C} = \frac{c_{ij}}{\sum_{i=k+1}^{L-1} \sum_{j=k+1}^{L-1} c_{ij}} \quad k+1 \leq i, j \leq L-1 \quad (\text{III.57})$$

$$p_{ij}^D = \frac{p_{ij}}{P_D} = \frac{c_{ij}}{\sum_{i=k+1}^{L-1} \sum_{j=0}^k c_{ij}} \quad k+1 \leq i \leq L-1, 0 \leq j \leq k \quad (\text{III.58})$$

III.3.2 Les entropies locale et jointe

Les entropies locale et jointe $H_{local}(k)$ et $H_{joint}(k)$, respectivement, sont introduites par Pal et al. [128] pour tirer profit de la corrélation spatiale dans une image. Elles sont définies comme:

$$H_{local}(k) = H_A(k) + H_C(k) = -\frac{1}{2} \sum_{i=0}^k \sum_{j=0}^k p_{ij}^A \log p_{ij}^A - \frac{1}{2} \sum_{i=k+1}^{L-1} \sum_{j=k+1}^{L-1} p_{ij}^C \log p_{ij}^C \quad (\text{III.59})$$

$$H_{joint}(k) = H_B(k) + H_D(k) = -\frac{1}{2} \sum_{i=0}^k \sum_{j=k+1}^{L-1} p_{ij}^B \log p_{ij}^B - \frac{1}{2} \sum_{i=k+1}^{L-1} \sum_{j=0}^k p_{ij}^D \log p_{ij}^D \quad (\text{III.60})$$

$H_A(k)$ et $H_C(k)$ sont les entropies locales des objets et du fond, respectivement. $H_B(k)$ et $H_D(k)$ sont les entropies des frontières en transitant des objets au fond et du fond aux objets, respectivement. Ces deux algorithmes sélectionnent les seuils qui maximisent $H_{local}(k)$ et $H_{joint}(k)$ sur k . En d'autres termes :

$$k_{Ent_loc}^* = \arg \max_k (H_{local}(k)) \quad (\text{III.61})$$

et

$$k_{Ent_joi}^* = \arg \max_k (H_{joint}(k)) \quad (\text{III.62})$$

Remarque : Dans le cas de notre application, les objets ont généralement des niveaux de gris plus sombres par rapport au fond.

III.3.3 L'entropie relative

La méthode d'entropie relative tente de trouver un seuil qui minimise l'erreur d'appariement entre les probabilités de transition de l'image binarisée et celles de l'image originale en niveaux de gris. Plus est petite l'entropie relative, meilleurs est l'appariement entre l'image en niveau de gris et sa version binarisée. En se référant à la définition de la divergence de Kullback-Leibler, Chang et al. [130] définissent donc l'entropie relative des distributions de probabilité P_{ij} et P'_{ij} comme suit:

$$L(p; p') = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p_{ij} \log \frac{p_{ij}}{p'_{ij}} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p_{ij} \log p_{ij} - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p_{ij} \log p'_{ij} \quad (\text{III.63})$$

où P_{ij} et P'_{ij} sont les distributions de probabilité de transition du niveau de gris i au niveau de gris j de l'image originale et l'image binarisée, respectivement. Dans chaque quadrant, P'_{ij} peut être définie pour l'image binaire comme suit :

$$p_{ij}^{(A)}(k) = q_A(k) = \frac{P_A(k)}{(k+1) \times (k+1)}, \quad 0 \leq i, j \leq k \quad (\text{III.64})$$

$$p_{ij}^{(B)} = q_B(k) = \frac{P_B(k)}{(k+1) \times (L-k-1)}, \quad 0 \leq i \leq k, k+1 \leq j \leq L-1 \quad (\text{III.65})$$

$$p_{ij}^{(C)} = q_C(k) = \frac{P_C(k)}{(L-k-1) \times (L-k+1)}, \quad k+1 \leq i, j \leq L-1 \quad (\text{III.66})$$

$$p_{ij}^{(D)} = q_D(k) = \frac{P_D(k)}{(L-k-1) \times (k+1)}, \quad k+1 \leq i \leq L-1, 0 \leq j \leq k \quad (\text{III.67})$$

Le premier terme du coté droit de (III.63) est indépendant du seuil k . Le second terme est simplifié comme suit :

$$\begin{aligned} \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p_{ij} \log p'_{ij} &= \sum_A p_{ij} \log q_A(k) + \sum_B p_{ij} \log q_B(k) + \sum_C p_{ij} \log q_C(k) + \sum_D p_{ij} \log q_D(k) \\ &= P_A(k) \log q_A(k) + P_B(k) \log q_B(k) + P_C(k) \log q_C(k) + P_D(k) \log q_D(k) \\ &= L'_{rel}(k) \end{aligned} \quad (\text{III.68})$$

Minimiser $L(p;p')$ est équivalent à maximiser $L'_{rel}(k)$ selon k . Il vient que le seuil optimal est

$$k_{Ent_rel}^* = \arg \max_k (L'_{rel}(k)) \quad (\text{III.69})$$

III.4 Seuillage localement adaptatif

III.4.1 Méthode de Niblack

Certaines images radiographiques présentent des fonds à luminance non uniforme, dus principalement aux variations de l'épaisseur de la structure soudée et la technique de radiographie utilisée. Ainsi, le chevauchement entre les deux classes d'objet et de fond est très large. Les méthodes locales de binarisation tentent de pallier à ce problème en calculant des seuils individuellement pour chaque pixel en utilisant l'information conférée par le voisinage du pixel en question. Dans ce cas, un seuil $T(x,y)$ peut être calculé pour chaque pixel (x,y) , et le seuillage peut être formulé par :

$$b(x, y) = \begin{cases} 0 & \text{si } f(x, y) < T(x, y) \\ 1 & \text{ailleurs} \end{cases} \quad (\text{III.70})$$

où f est l'image d'entrée en niveau de gris et b l'image de sortie binaire.

Ces méthodes sont habituellement capables d'aboutir à de bons résultats pour ce type d'images, mais elles sont souvent lentes puisque le calcul des paramètres statistiques de l'image à partir du voisinage local doit être fait pour chaque pixel de l'image [131].

Dans la méthode Niblack [132], la valeur du seuil est calculée pour chaque pixel en se basant sur la moyenne et l'écart type de tous les pixels d'un voisinage local. Une fenêtre de taille $W \times W$ se déplace sur l'image et la valeur du seuil, pour chaque pixel (x,y) , est calculé comme

$$T(x, y) = \mu(x, y) + k\sigma(x, y) \quad (\text{III.71})$$

où $\mu(x,y)$ et $\sigma(x,y)$ sont les valeurs de la moyenne et l'écart type, respectivement, dans le voisinage considéré. Les expressions de $\mu(x,y)$ et $\sigma(x,y)$ sont données comme suit :

$$\mu(x, y) = \frac{1}{W^2} \sum_{i=-\frac{W-1}{2}}^{\frac{W-1}{2}} \sum_{j=-\frac{W-1}{2}}^{\frac{W-1}{2}} f(x+i, y+j) \quad (\text{III.72})$$

$$\sigma(x, y) = \left[\frac{1}{W^2} \sum_{i=-\frac{W-1}{2}}^{\frac{W-1}{2}} \sum_{j=-\frac{W-1}{2}}^{\frac{W-1}{2}} (f(x+i, y+j) - \mu(x, y))^2 \right]^{1/2} \quad (\text{III.73})$$

Les paramètres W et k ont une grande influence sur les résultats de segmentation. La taille de la fenêtre doit être assez petite pour préserver les détails, mais aussi doit être assez grande pour éliminer le bruit. La valeur de k est utilisée pour répondre à la question suivante : quelles sont les frontières de l'objet retenues lors de la binarisation ? Il est naturellement difficile de déterminer les meilleurs paramètres W et k , lesquels seront choisis empiriquement. Cependant, cette méthode tend à produire une grande quantité de bruit de binarisation dans les régions du fond de l'image particulièrement, lorsque ce dernier contient des textures claires.

III.4.2 Méthode de Sauvola

Pour pallier au problème mentionné plus haut, Sauvola et al. [133] ont proposé un nouvel algorithme pour le calcul de la valeur du seuil en guise d'amélioration de la méthode de Niblack :

$$T(x, y) = \mu(x, y) [1 - k(1 - \sigma(x, y) / R)] \quad (\text{III.74})$$

où R est la valeur maximale de l'écart type ($R = 128$ pour une image en 256 niveaux de gris), et k est un paramètre qui prend des valeurs positives dans l'intervalle $[0.2 \ 0.5]$ [131].

La moyenne et l'écart type locaux $\mu(x,y)$ et $\sigma(x,y)$ adaptent la valeur du seuil selon le contraste dans le voisinage local du pixel. Lorsqu'il y a un contraste élevé dans certaines régions de l'image, $\sigma(x,y) \approx R$ qui implique que $T(x,y) \approx \mu(x,y)$. C'est le même résultat que la méthode de Niblack. Cependant, la différence devient perceptible quand le contraste dans le voisinage local est relativement faible. Dans ce cas le seuil $T(x,y)$ passe au dessous de la valeur moyenne

éliminant ainsi d'une manière efficace les régions relativement sombres du fond. Le paramètre k contrôle la valeur du seuil dans la fenêtre locale de sorte que plus la valeur de k est grande, plus la valeur du seuil à partir de la moyenne locale est faible. En général, cet algorithme n'est pas très sensible à la valeur de k utilisée.

III.5 Critère de mesure de la performance du seuillage

Dans des applications pratiques de seuillage, si l'image à binariser est complexe et l'algorithme est entièrement automatique, l'erreur est inévitable.

La disparité entre l'image réellement binarisée et l'image correctement ou idéalement binarisée (image binaire de référence) qui est le meilleur résultat prévu peut être employée pour évaluer la performance des algorithmes [122]. Dans le cas des images radiographiques des joints soudés, le seuillage automatique d'images rencontre des difficultés parce que les niveaux de gris de l'objet (défaut de soudure) et du fond possèdent des distributions qui se chevauchent substantiellement, présentant souvent une distribution à un seul mode. En conséquence, les pixels mal classifiés et les déformations de forme de l'objet peuvent compromettre les résultats de l'interprétation du film radiographique. Pour cette raison, les critères pour évaluer des algorithmes de seuillage doivent prendre en considération non seulement le caractère bruyant de la topographie de segmentation mais aussi la déformation de l'aspect des défauts de soudure.

Pour mettre en évidence les différentes caractéristiques de performance des méthodes de seuillage [120], nous avons utilisé les quatre critères de performance suivants: erreur de classification (ME), erreur relative de l'aire d'objet (RAE), la non uniformité (irrégularité) de région (NU), et la mesure de déformation de forme (SM).

Nous avons ajusté ces mesures de performance de sorte que leurs résultats varient de 0 pour une segmentation totalement correcte à 1 pour une segmentation totalement erronée.

III.5.1 Erreur de classification

L'erreur de classification (ME) [134] reflète le pourcentage des pixels de fond affectés par erreur à l'objet, et inversement, les pixels de l'objet affectés par erreur au fond. Pour un problème de segmentation en deux classes, ME peut être simplement exprimée comme:

$$ME = 1 - \frac{|C_{0Id} \cap C_{0k}| + |C_{1Id} \cap C_{1k}|}{|C_{0Id}| + |C_{1Id}|} \quad (\text{III.75})$$

où C_{0Id} et C_{1Id} dénotent, respectivement, les pixels de l'objet et du fond de l'image binaire idéale. C_{0k} et C_{1k} dénotent, respectivement, les pixels des régions de l'objet et du fond dans l'image binarisée. $|\cdot|$ est utilisé pour désigner le cardinal d'ensemble.

III.5.2 Non uniformité de région

Ce critère, [122,135] qui n'exige pas d'information sur l'image binaire idéale, juge la qualité intrinsèque des régions segmentées. Il est défini comme

$$NU = \frac{|C_{0k}|}{|C_{0k} + C_{1k}|} \frac{\sigma_0^2}{\sigma_T^2} \quad (\text{III.76})$$

où σ_T^2 représente la variance de l'image totale, et σ_0^2 représente la variance de l'objet.

III.5.3 Erreur relative de la région d'objet

La comparaison des propriétés d'objet telles que la surface et la forme, telles obtenues de l'image segmentée avec l'image de référence, est utilisée dans [122] sous le nom de précision de mesure finale relative (*RUMA*) pour refléter la précision de la caractéristique de mesure. Nous modifions cette mesure pour l'attribut de surface comme suit :

$$RAE = \begin{cases} \frac{A_{Id} - A_k}{A_{Id}} & \text{si } A_k < A_{Id} \\ \frac{A_k - A_{Id}}{A_k} & \text{si } A_k \geq A_{Id} \end{cases} \quad (\text{III.77})$$

où A_{Id} et A_k sont les surfaces des régions de l'objet dans l'image binaire de référence et l'image binarisée, respectivement.

III.5.4 Critère basé sur la forme de la région

Non seulement le niveau gris, mais également la forme d'une région segmentée peuvent être pris en considération pour concevoir un critère de qualité afin de satisfaire l'intuition humaine sur une segmentation "idéale". Ainsi, pour expliquer des inexactitudes de forme, Sahoo et al. [136] ont proposé une mesure de forme (*SM*) pour l'évaluation du seuillage. Ils considèrent un voisinage de taille 3×3 centré sur le pixel courant (x,y) de niveau de gris $f(x,y)$, et définissent un gradient général $\Delta(x,y)$, comme la somme des vecteurs des racines carrées moyennes de la différence des niveaux de gris dans chacune des quatre directions. On a légèrement modifiée la version originale de la mesure de forme afin d'ajuster cette mesure de sorte que ses résultats varient entre 0, pour une segmentation correcte, et 1 pour un cas incorrect. La mesure de forme (*SM*) à un seuil k est alors donné par :

$$SM = 1 - \frac{\sum_{x,y} \text{sgn}(f(x,y) - \overline{f_w(x,y)}) \Delta(x,y) \text{sgn}(f(x,y) - k)}{C} \quad (\text{III.78})$$

où, $\text{sgn}(x) = -1$ ou 1 selon si x est négatif ou non, $\overline{f_w(x,y)}$ est la moyenne des niveaux de gris du voisinage $W(x,y)$ et C le facteur de normalisation lié à la surface de la région et l'étendue des ses niveaux de gris.

Le calcul de la valeur du gradient généralisé $\Delta(x,y)$ du pixel (x,y) est réalisé en utilisant la formule

$$\Delta(x, y) = \left[\sum_{i=1}^4 D_i^2 + \sqrt{2}D_1(D_3 + D_4) - \sqrt{2}D_2(D_3 - D_4) \right]^{1/2} \quad (\text{III.79})$$

$$\text{où} \quad \begin{cases} D_1 = f(x+1, y) - f(x-1, y), \\ D_2 = f(x, y-1) - f(x, y+1), \\ D_3 = f(x+1, y+1) - f(x-1, y-1), \\ D_4 = f(x+1, y-1) - f(x-1, y+1). \end{cases}$$

La mesure de forme estime un seuil tel que tous les points avec un gradient positif soient au-dessus du seuil, et les points avec un gradient négatif soient au-dessous du seuil. Le terme « mesure de forme » semble être un terme mal approprié, parce qu'elle dépend principalement de l'hypothèse que les régions soient uniformes et les gradients de niveau gris dans l'image correspondent aux transitions entre les deux régions à séparer.

Pour les méthodes de seuillage localement adaptatives, nous avons adapté la mesure de forme de sorte qu'elle tienne compte du seuil spatial $T(x,y)$ pour nous donner la version suivante du critère [14] :

$$SM = 1 - \frac{\sum_{x,y} \text{sgn}(f(x, y) - \overline{f_N(x, y)}) \Delta(x, y) \text{sgn}(f(x, y) - T(x, y))}{C} \quad (\text{III.80})$$

III.5.5 Combinaison des mesures

Pour obtenir une valeur moyenne du critère de performance à partir des quatre critères, nous avons considéré la moyenne arithmétique des valeurs normalisées obtenues à partir des critères : ME , NU , RAE et SM . En d'autres termes, étant donné un algorithme de seuillage, pour chaque image la moyenne de ME , NU , RAE et SM est une indication de sa qualité de segmentation. Ainsi, la mesure de performance pour la $i^{\text{ème}}$ image segmentée est exprimée en termes des quatre métriques comme :

$$S(i) = (ME(i) + NU(i) + RAE(i) + SM(i)) / 4 \quad (\text{III.81})$$

La mesure du critère de performance pour la totalité des images pour une méthode de seuillage donnée est définie comme une mesure moyenne

$$S_t = \left(\sum_{i=1}^{N_b} S(i) \right) / N_b \quad (\text{III.82})$$

avec N_b le nombre des images binarisées.

III.6 Morphologie mathématique et post-traitement

Après le seuillage, les parties de l'image sélectionnées seront traduites en noir et blanc, formant l'image binaire. Cette dernière, tout comme l'image numérique, contient des informations superfétatoires qu'il convient d'éviter, ou masquées qu'il faut révéler et ce, quelque soit la méthode de seuillage employée. Les traitements se basant sur la morphologie mathématique permettent de modifier l'image binaire à ces fins.

La morphologie mathématique [137] est une méthode de description de la forme des objets par la comparaison avec des objets de formes connues : les éléments structurants. Les éléments structurants les plus employés sont les éléments convexes tels que le segment et surtout le disque qui est isotrope.

Les opérations morphologiques tendent à simplifier les données « image » en préservant leurs caractéristiques essentielles de forme et en éliminant les résidus inutiles [138]. La dilatation et l'érosion sont deux opérations morphologiques de base. Il y a plusieurs manières pour définir les opérations de la dilatation et de l'érosion pour les images binaires.

Soit $b(x,y)$ une image binaire où les pixels ont les valeurs 1 ou 0, et $B(x,y)$ un élément structurant qui est un masque de taille $m \times n$ formés des 1 et 0.

La définition de l'opération de dilatation $b_{out} = b_{in} \oplus H$ donnée par Pratt [26] est :

$$b_{out}(x, y) = \bigcup_m \bigcup_n b_{in}(m, n) B(x - m + 1, y - n + 1) \quad (\text{III.83})$$

et celle de l'opération d'érosion $b_{out} = b_{in} \ominus B$ est

$$b_{out}(x, y) = \bigcap_m \bigcap_n b_{in}(m, n) \overline{B}(x - m + 1, y - n + 1) \quad (\text{III.84})$$

où \bigcup et \bigcap sont respectivement les symboles des opérations logiques de l'union et de l'intersection et \overline{B} est le complément de B obtenu par l'application des opérations logiques *NON* à tous les pixels dans B . Généralement, un élément structurant B est représenté par un petit objet, souvent un disque ou une autre forme simple. La taille de ces objets détermine le degré de la dilatation ou de l'érosion. Les objets dans l'image binaire s'épaississent après une dilatation et s'amincissent après une érosion par un disque comme élément structurant. A partir de (II.83) et (II.84), on remarque que ces deux opérations peuvent être implémentées comme des opérations de convolution. On en donne ici quelques propriétés :

- Ces deux opérations ne sont pas idempotentes mais itératives. L'érosion, appliquée un grand nombre de fois, aboutit à la disparition de l'objet. On dit qu'une transformation est idempotente si, après transformation, le résultat reste invariant par cette dernière.
- L'érosion et la dilatation ne sont pas homotopiques. Une transformation homotopique est une transformation qui ne modifie pas le nombre de composantes connexes. La dilatation préserve la connexité si l'élément structurant est connexe. L'érosion ne préserve pas la connexité.

- Il est équivalent d'éroder (respectivement de dilater) n fois un objet par un élément structurant de taille unité et d'éroder (respectivement de dilater) une fois ce même objet par le même élément structurant de taille n . Cette propriété est intéressante dans la mesure où elle permet de limiter le nombre d'éléments structurants en mémoire.

Les dilations et les érosions sont souvent utilisées par paire pour obtenir l'ouverture et la fermeture morphologiques. L'ouverture d'une image b par un élément structurant B , notée par $b \circ B$, est défini comme :

$$b \circ B = (b \ominus B) \oplus B \quad (\text{III.85})$$

Elle n'est autre qu'une érosion suivie d'une dilatation. L'ouverture joue le rôle d'un filtrage sur l'image binaire. $b \circ B$ est plus régulier et moins riche en détails que b . Elle adoucit les contours, coupe les isthmes étroits, supprime les petites îles et les caps étroits.

La fermeture d'une image b par B , notée $b \bullet B$, est définie comme :

$$b \bullet B = (b \oplus B) \ominus B \quad (\text{III.86})$$

Elle n'est autre qu'une dilatation suivie d'une érosion. La fermeture a également un effet de lissage sur l'image binaire, elle bouche les canaux étroits, supprime les petits lacs et les golfs étroits.

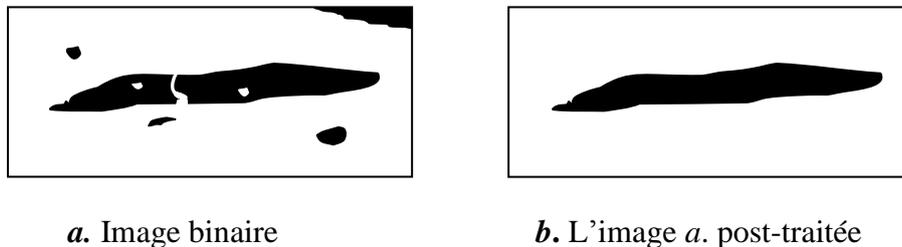


Fig. III.3 Principe d'un post-traitement

En se référant aux propriétés de la dilatation, de l'érosion, de l'ouverture et de la fermeture morphologiques citées ci dessus, il devient donc opportun d'appliquer ces opérateurs, ainsi que leur combinaison afin d'éliminer le bruit et les petites taches résiduelles dans l'image binarisée, issue de l'opération de seuillage. A titre illustratif, voir la Figure III.3. On doit considérer qu'à l'issue de cette étape, on n'obtient qu'une seule région connexe représentant la région de l'objet et sur lequel vont être calculés les différents attributs et qui feront l'objet de notre travail dans le chapitre 5 faisant partie de la 2^{ème} partie du manuscrit.

III.7 Résultats expérimentaux

Pour évaluer les performances des algorithmes de seuillage proposés pour la détection des défauts de soudures, nous avons considéré un échantillon de huit images, montrés en niveau de gris dans Fig. III.4 et Fig. III.5. Dans le jargon des interpréteurs en radiographie, ils sont appelés inclusion solide (pour Images 1,2 et 3), porosité (pour Image 4), fissure transversale (pour Image 5), caniveau externe (pour Image 6) et manque de pénétration (pour Images 7 et 8). Ces images représentent différents niveaux de complexité, traduite par des histogrammes de formes compliquées, à cause de plusieurs facteurs déjà mentionnés dans l'introduction de ce document. Pour des objectifs de comparaison, les images considérées ont été binarisées par des experts en radiographie. Les images initiales des défauts de soudures, leurs images binaires de référence et leurs versions binaires issues des différents algorithmes sont illustrés dans Fig. III.4 et Fig. III.5. Tableau III.1 donne les résultats d'évaluation des algorithmes sélectionnés, rangés selon leur efficacité de seuillage sur les images considérées. Les algorithmes basés sur l'histogramme 1D considère juste les statistiques globales des niveaux de gris de l'image d'entrée et n'implique pas la relation spatiale entre les pixels. Ces méthodes de seuillage sont recommandées particulièrement lorsque l'histogramme des niveaux de gris apparaît comme une distribution bimodale. D'un autre côté dans les méthodes de seuillage basées sur l'histogramme 2D, la relation spatiale entre les pixels est considérée. C'est pourquoi, pour les images d'entrée avec un certain chevauchement entre l'objet et le fond, l'approche basée sur l'histogramme 2D peut fournir de meilleurs résultats. Néanmoins, cette bonne performance n'est pas toujours garantie puisque le résultat dépend réellement de la particularité de l'image d'entrée et de l'objet que l'on désire réellement obtenir.

Les principales caractéristiques de la plupart des images testées sont une luminance variable, un faible contraste et un bruit très accentué. Ainsi, pour de telles images, les méthodes de seuillage localement adaptatives sont vivement recommandées.

L'examen visuel et les résultats des mesures d'évaluation, comme les montrent les figures et la table indiquent que les techniques adaptatives semblent avoir la performance la plus satisfaisante. Le mauvais comportement des méthodes globales peut être expliqué par le fait que les images testées offrent un fond à luminance variable, qui apparaît être fusionné avec la région du défaut dans certain endroit.

Par exemple, pour toutes les méthodes globales, le défaut de soudure dans Image 6 est totalement noyée dans le fond. Par conséquent, cette détection erronée du défaut peut induire en erreur le radiographe lors de l'interprétation du radiogramme. La même remarque peut être faite pour Images 1, 3 et 4, où l'aspect du défaut de soudure ne peut apparaître, excepté pour les méthodes de Kapur et l'entropie jointe dans le cas d'Image 4. Toujours pour la totalité des images, la méthode de Kapur surpasse en performance le reste des méthodes basées sur l'histogramme 1D, tandis que la méthode de l'entropie relative est relativement la meilleure parmi les techniques basées sur l'histogramme 2D. Quant aux méthodes adaptatives, celle de Niblack extrait les défauts correctement mais souffre du bruit de fond comme le montre Image 7. L'algorithme de Sauvola solutionne ce problème mais son hypothèse additionnelle est la cause dans l'amincissement des objets.

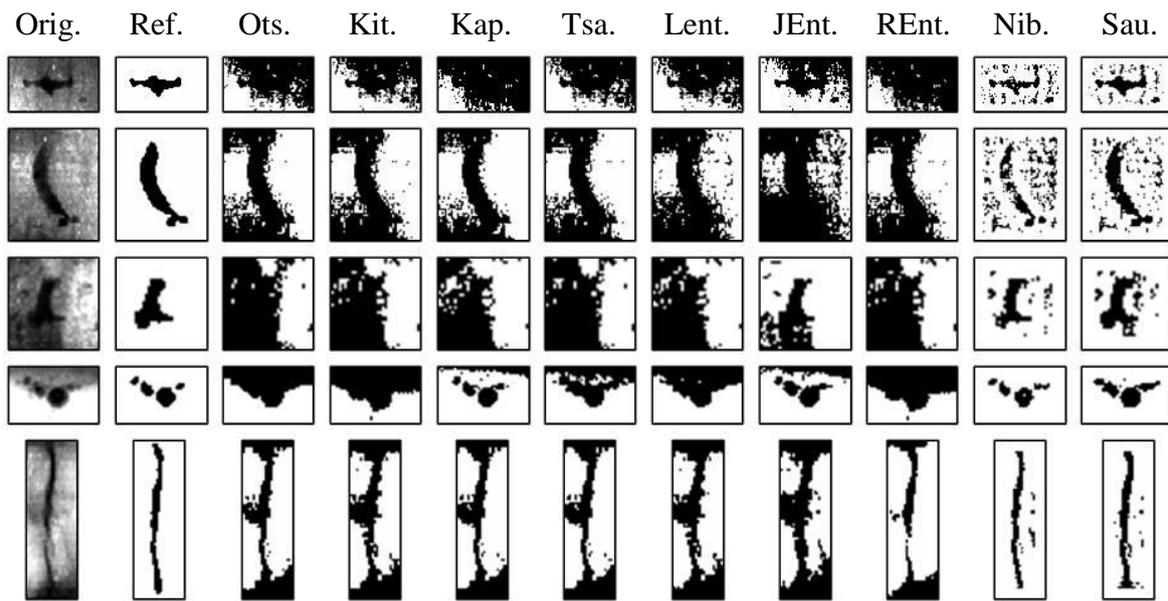


Fig. III.4 Résultats de seuillage pour Images 1 à 5 (de haut en bas)

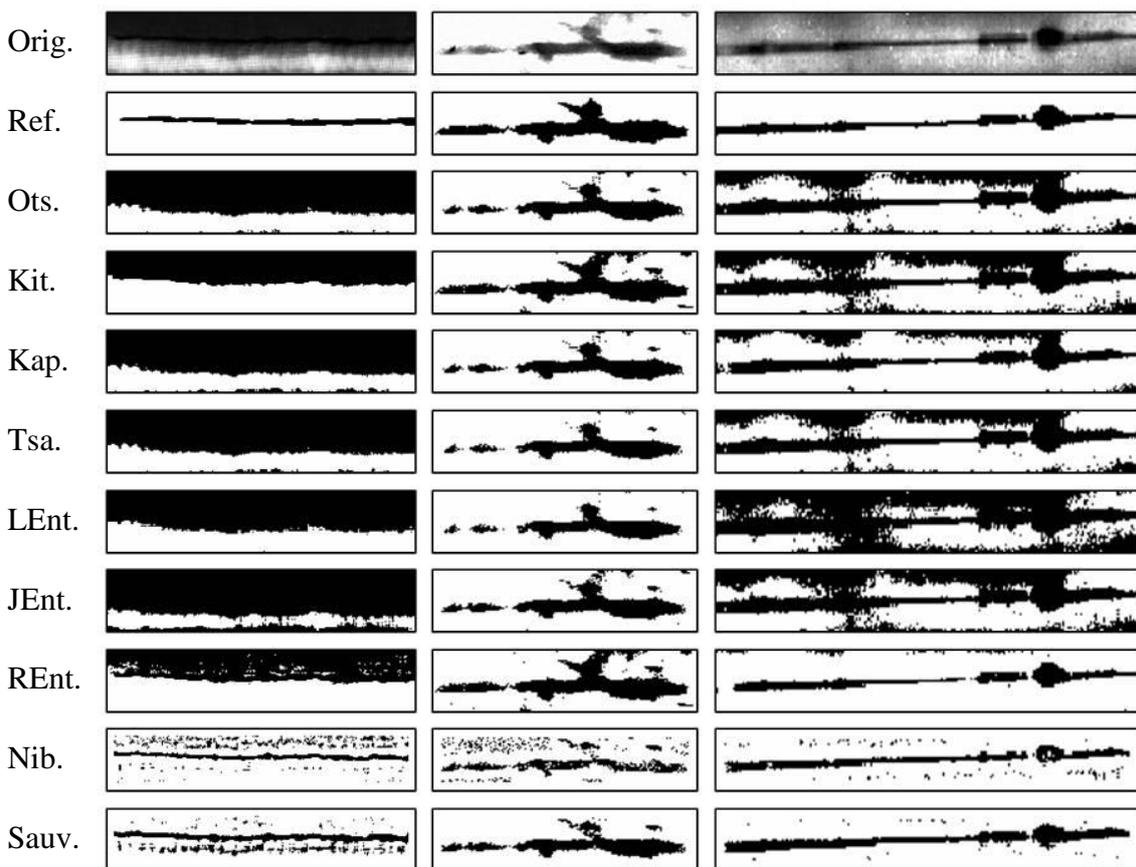


Fig. III.5 Résultats de seuillage pour Images 6 à 8 (de gauche à droite)

Finale­ment, à l'exception des méthodes localement adaptatives qui surpassent toutes les autres méthodes, il semble qu'aucune des autres méthodes qu'aucune des autres méthodes n'est la meilleure ou la plus mauvaise et elles présentent toutes des points forts et des insuffisances comparées les unes aux autres selon des cas particuliers. En outre, le problème principal dans le développement d'un système de détection de défaut de soudure qui peut être exploité pratiquement (contrôle en temps réel, etc.), semble être dans l'atteinte d'un équilibre entre la vitesse d'exécution d'un algorithme et la précision de sa segmentation. Dans cette perspective, nous pouvons constater que les algorithmes basés sur l'histogramme 2-D sont les plus lents en termes de temps de calcul, méthodes, tandis que les méthodes basées sur l'histogramme 1-D sont les plus rapides du moment qu'elles ont beaucoup moins de calculs à faire. L'utilisation des opérateurs morphologiques de dilatation et d'érosion nous permet de filtrer le bruit, éliminer les petites taches résiduelles et de connecter entre elles certaines régions connexes susceptibles de représenter le même défaut comme l'illustre Fig. III.6.

Tableau III.1 Résultats d'évaluation du seuillage pour les images testées

	<i>Im.1</i>	<i>Im.2</i>	<i>Im.3</i>	<i>Im.4</i>	<i>Im.5</i>	<i>Im.6</i>	<i>Im.7</i>	<i>Im.8</i>	S_t
<i>Ots.</i>	0.586 [7]	0.492 [4]	0.557 [9]	0.444 [7]	0.456 [4]	0.614 [5]	0.199 [4]	0.435 [6]	0.473 [7]
<i>Kit.</i>	0.531 [4]	0.516 [7]	0.529 [6]	0.581 [8]	0.510 [7]	0.558 [4]	0.231 [6]	0.491 [7]	0.493 [8]
<i>Kap.</i>	0.677 [9]	0.475 [3]	0.498 [4]	0.272 [3]	0.467 [5]	0.624 [8]	0.198 [3]	0.358 [4]	0.446 [3]
<i>Tsa.</i>	0.560 [6]	0.500 [5]	0.541 [8]	0.384 [5]	0.467 [5]	0.619 [7]	0.227 [5]	0.434 [5]	0.467 [5]
<i>L.Ent.</i>	0.550 [5]	0.553 [8]	0.520 [5]	0.425 [6]	0.514 [8]	0.603 [5]	0.241 [8]	0.615 [9]	0.503 [9]
<i>J.Ent.</i>	0.504 [3]	0.631 [9]	0.372 [3]	0.318 [4]	0.563 [9]	0.699 [9]	0.174 [1]	0.498 [8]	0.470 [6]
<i>R.Ent.</i>	0.672 [8]	0.515 [6]	0.529 [6]	0.598 [9]	0.362 [3]	0.547 [3]	0.233 [7]	0.206 [2]	0.458 [4]
<i>Nib.</i>	0.326 [2]	0.326 [2]	0.205 [1]	0.162 [1]	0.171 [1]	0.331 [2]	0.352 [9]	0.191 [1]	0.258 [2]
<i>Sauv.</i>	0.299 [1]	0.282 [1]	0.237 [2]	0.170 [2]	0.234 [2]	0.315 [1]	0.193 [2]	0.214 [3]	0.243 [1]

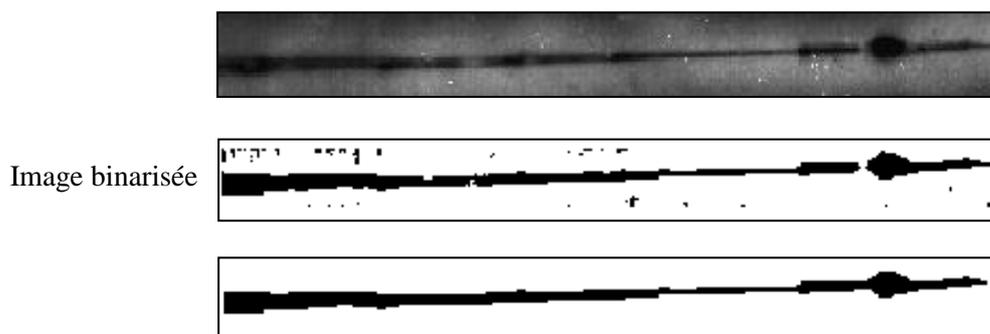


Fig. III.6 Exemple d'un post-traitement sur une image binaire d'un défaut de soudure

III.8 Conclusion

Dans ce chapitre, nous avons étudié expérimentalement l'efficacité des méthodes de seuillage basées sur les histogrammes 1-D et 2-D et les méthodes de seuillage localement adaptatives à travers des images radiographiques des joints soudés. Pour évaluer la qualité de ces techniques de seuillage, un critère de performance est calculé sur les images binarisées. En comparant toutes les méthodes proposées pour les images bien contrastées, la méthode de Kapur s'avère la meilleure pour l'approche de seuillage basée sur l'histogramme 1-D. L'entropie relative est légèrement plus efficace que les autres méthodes dans l'approche basée sur l'histogramme 2-D. Selon les résultats obtenus pour l'ensemble des images testées, les méthodes localement adaptatives, particulièrement la méthode de Sauvola, s'avèrent être l'outil de seuillage le plus puissant. Pour récapituler les résultats principaux présentés dans ce travail, nous notons que généralement, les méthodes globales de seuillage donnent de bons résultats pour des images radiographiques des défauts de soudure bien contrastées. Dans le cas des images avec un fond à luminance non uniforme, les méthodes de Niblack et Sauvola sont plus recommandées. Néanmoins, dans la méthode du Niblack, le problème existe pour les textures claires du fond, qui sont assimilées à des objets avec un faible contraste. Pour pallier à ce problème, la méthode de Sauvola peut être appliquée.

En général, les algorithmes basés sur l'histogramme 1-D sont beaucoup plus rapides que ceux basés sur l'histogramme 2-D et ceux des méthodes localement adaptatives, puisqu'ils nécessitent beaucoup moins de calculs. Pour l'extraction de la région du défaut, on peut appliquer d'une manière interactive le filtre médian et/ou les opérateurs morphologiques pour l'élimination des petites taches et des petits trous et pour la connexion des régions intimement voisines.

Chapitre 4

Segmentation d'images par un modèle de mélange de lois gaussiennes généralisées

IV.1 Introduction

La modélisation de la distribution des données observées avec une approche paramétrique est un outil important dans le traitement des signaux statistiques. Dans les applications où les données ont beaucoup de groupes (ang. *clusters*), comme la segmentation d'image, une représentation du modèle probabiliste multi-composant telle que le modèle de mélange est exigée. Dans les approches paramétriques les classes constituant les différentes partitions de l'image sont séparées d'une part ;

(1) en considérant un modèle statistique pour approcher les distributions des densités des classes et d'autre part,

(2) en déterminant les valeurs optimales des seuils comme fonctions des paramètres de classes (cas du seuillage multimodal) ou bien les estimations des probabilités *a posteriori* pour les différentes classes dépendant des paramètres du modèle considéré (cas des modèles de mélanges).

La plupart des approches paramétriques considèrent des modèles de mélanges utilisant la distribution gaussienne (GMM) pour leur simplicité de calcul. Cependant, les histogrammes de niveaux de gris des images réelles peuvent présenter des formes tellement complexes qu'on ne peut se suffire de les considérer comme un mélange de lois de probabilités gaussiennes comme nous le verrons plus tard dans la partie expérimentale. A cet effet et pour surpasser les limitations présentées par de tels modèles, nous proposons dans ce travail un autre modèle de mélange de sorte que les partitions de l'image obtenues à l'issue de la segmentation correspondent le mieux possible aux différentes composantes contenues dans l'image réelle. Les modèles paramétriques basés sur la distribution gaussienne généralisée peuvent répondre à cette attente car ils peuvent se substituer à un grand nombre de distributions (Laplace, Gauss, uniforme, etc.), ce qui leurs confèrent une propriété principale à savoir la flexibilité i.e. ils doivent être capables de modéliser une grande variété de modèles statistiques.

Allili et al. [139] ont utilisé les modèles de mélanges de gaussiennes généralisées (GGMM) pour l'extraction des objets dans des images et dans des scènes de vidéo en estimant directement les paramètres du mélange par les multiplicateurs de Lagrange. Dans [140], les auteurs ont adopté les GGMM dans le seuillage bimodal d'images en utilisant l'algorithme EM [141]. Les auteurs dans [142], proposent une méthode d'estimation rapide des paramètres du GGMM basé sur un algorithme qui combine entre l'algorithme EM et un algorithme évolutionnaire PSO (ang. *particle swarm optimization*).

Dans ce chapitre, nous proposons l'application des GGMMs, utilisant l'algorithme EM pour l'estimation des paramètres du mélange, dans la segmentation multimodale d'images de radiographie des joints soudés [19]. En plus de la connaissance parfaite de la géométrie de ces

défauts de soudures, leurs localisations par rapport au cordon de soudure et au métal de base peut être une étape indispensable pour apprécier la qualité de la soudure. Cette fois-ci, à l'inverse des deux chapitres précédents, l'image totale du radiogramme est utilisée à la place de la région d'intérêt. Dans l'évaluation des résultats de segmentation, la capacité de travailler sans les images de référence permet une évaluation non supervisée pour opérer sur un grand éventail de conditions ou systèmes (par exemple : système en temps réel) et avec plusieurs types d'images. Ainsi, un critère d'évaluation basé sur l'homogénéité des régions [143] est utilisé pour comparer les résultats de segmentation entre les GMMs et les GGMMs.

IV.2 Modèle de mélanges et algorithme EM

Soit $\chi = \{x_1, x_2, \dots, x_N\}$ un ensemble de N réalisations d'un vecteur aléatoire X de dimension d et avec une densité de probabilité $f(x_i)$, $i = 1, \dots, N$. Nous pouvons donc écrire la fonction de densité paramétrée comme une combinaison de fonctions de densité de M composantes C_m ($m = 1, \dots, M$) caractérisant ainsi un modèle de mélange fini :

$$f(x_i | \Theta) = \sum_{m=1}^M \pi_m f_m(x_i | \theta_m) \quad (\text{IV.1})$$

où $\Theta = (\pi_1, \dots, \pi_M, \theta_1, \dots, \theta_M)$ est le vecteur de paramètres à estimer avec π_m est la probabilité *a priori* de la $m^{\text{ième}}$ composante qui satisfait les conditions suivantes :

$$\pi_m \geq 0 \text{ et } \sum_{m=1}^M \pi_m = 1 \quad (\text{IV.2})$$

En présence d'observations indépendantes, la vraisemblance peut être exprimée comme :

$$L(\Theta) = \prod_{i=1}^N f(x_i | \Theta) = \prod_{i=1}^N \sum_{m=1}^M \pi_m f_m(x_i | \theta_m) \quad (\text{IV.3})$$

Etant donné, le vecteur aléatoire χ une observation partielle du phénomène considéré, la maximisation de $L(\Theta)$ est difficile à réaliser directement. Il y a donc opportunité d'utiliser l'algorithme EM qui est une technique itérative de maximisation de loi de vraisemblance en présence de données incomplètes.

On introduit une variable aléatoire Z correspondant aux données manquantes telle que :

$$z_i = (z_{i,1}, \dots, z_{i,M}) \quad \text{où} \quad z_{i,m} = \begin{cases} 1 & \text{si } x_i \in C_m \\ 0 & \text{ailleurs} \end{cases} \quad (\text{IV.4})$$

L'idée de l'algorithme EM est de faciliter le processus d'optimisation en utilisant une estimation des données manquantes. Soit $Y = (\chi, Z)$ les données complètes, alors la log-vraisemblance complète sera :

$$\log L_c(\Theta / Y) = \sum_{i=1}^N \sum_{m=1}^M z_{i,m} \log[\pi_m f(x_i / \theta_m)] \quad (\text{IV.5})$$

Dans la suite, $L_c(\Theta)$ désigne $\log L_c(\Theta / Y)$. L'algorithme EM pour les modèles de mélange est donc donné comme suit :

Entrées : Nombre de modes M ; Paramètres initiaux $\Theta^{(0)}$; le seuil de convergence de l'algorithme ε

Sorties : Paramètres $\hat{\Theta}$ donnant un maximum de la loi de vraisemblance
 $t \leftarrow 0$;

Initialisation du modèle $\hat{\Theta}^{(t)} = \Theta^{(0)}$;

Répéter

(E-Step) Calcul des probabilités *a posteriori* $\hat{z}_{i,m}^{(t)}$

$$\hat{z}_{i,m}^{(t)} = \Pr(m/x_i, \Theta^{(t)}) = \pi_m f(x_i / \theta_m^{(t)}) / \sum_{l=1}^M \pi_l f(x_i / \theta_l^{(t)})$$

(M-Step) Maximisation de $L_c(\Theta)^{(t)}$

$$\hat{\Theta}^{(t+1)} = \arg \max_{\Theta} Q(\Theta / \hat{\Theta}^{(t)}) \quad \text{où} \quad Q(\Theta / \hat{\Theta}^{(t)}) = E[L_c(\Theta), \hat{\Theta}^{(t)}]$$

$t \leftarrow t+1$;

Jusqu'à $\|Q(\Theta / \hat{\Theta}^{(t)}) - Q(\Theta / \hat{\Theta}^{(t-1)})\| < \varepsilon$

IV.3 GGMM pour la segmentation

Soit h_g ($g \in [0, L-1]$ où L est le nombre de niveaux de gris) l'histogramme normalisé de l'image χ qui est une approximation de la densité de probabilité réelle de l'image. Pour segmenter l'image, chacun de ses pixels est affecté à l'une des différentes partitions ou régions de l'image. Par conséquent, on peut estimer l'histogramme des niveaux de gris par un mélange de distributions gaussiennes généralisées (DGG) monovariées, i.e. $d = 1$.

L'expression analytique de ces dernières est donné par

$$f_m(g / \theta_m) = \frac{\beta_m}{2\alpha_m \Gamma(1/\beta_m)} e^{-[|g - \mu_m| / \alpha_m]^{\beta_m}} \quad (\text{IV.6})$$

où $\theta_m = (\mu_m, \alpha_m, \beta_m)$ représente le vecteur dont les composantes sont : la moyenne, les paramètres d'échelle et de forme, respectivement, et Γ est la fonction gamma définie par $\Gamma(\xi) = \int_0^{\infty} e^{-t} t^{\xi-1} dt$. Le paramètre d'échelle qui exprime la largeur de la distribution est lié à l'écart type par l'équation :

$$\alpha_m = \sigma_m \sqrt{\Gamma(1/\beta_m) / \Gamma(3/\beta_m)} \quad (\text{IV.7})$$

Le paramètre de forme β_m ajuste le taux de décroissance de la densité de probabilité. Il est à noter que $\beta_m = 2$ donne une densité normale tandis que pour $\beta_m = 1$, on obtient la densité de Laplace. Dans les cas limites, pour $\beta_m \rightarrow 0$ la distribution devient la fonction impulsion tandis que pour $\beta_m \rightarrow \infty$ on obtient la distribution uniforme (voir Fig. IV.1).

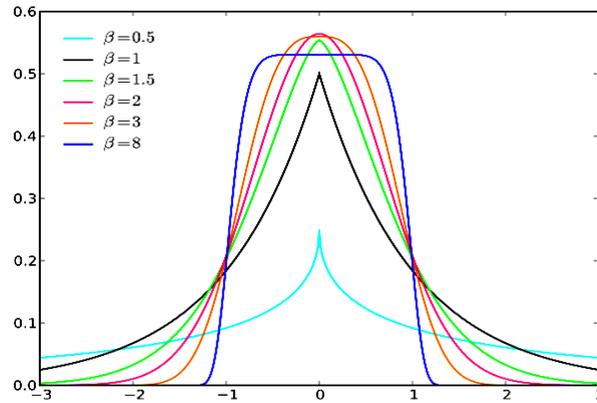


Fig. IV.1 Distribution gaussienne généralisée centrée pour différents paramètres de forme β

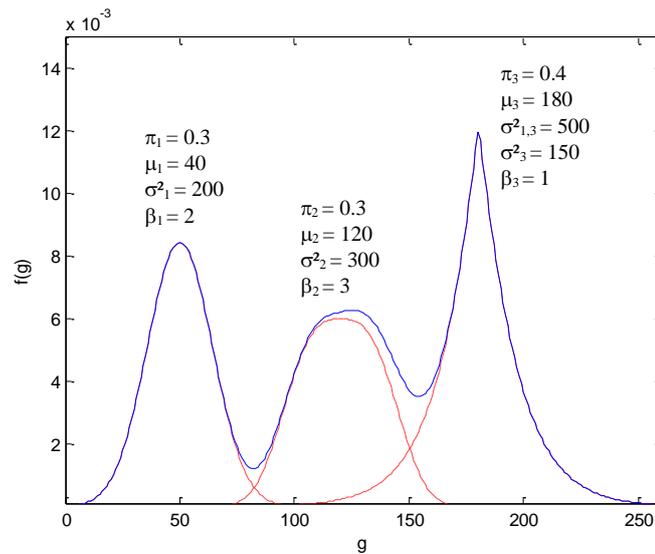


Fig. IV.2 Mélange de trois DGG avec des paramètres différents

Fig. IV.2 montre un exemple de mélange de trois DGG où les courbes en rouge représentent les fonctions f_m ($m = 1, 2, 3$) et la courbe en bleu est la somme des $f_m(\cdot)$ pondérées par les proportions du mélange π_m ($m = 1, 2, 3$), c'est-à-dire elle représente la fonction f dans (IV.1).

Pour un GGMM, la log-vraisemblance est exprimé par

$$L_c(\Theta) = \sum_{i=1}^N \sum_{m=1}^M z_{g,m} h_g \log[\pi_m f_m(g/\theta_m)] \quad (\text{IV.8})$$

où $\Theta = (\pi_m, \mu_m, \alpha_m, \beta_m)$.

Dans E-Step, les probabilités *a posteriori* sont données par

$$z_{g,m}^{(t)} = \pi_m f_m(g/\theta_m^{(t)}) / \sum_{l=1}^M \pi_l f_l(g/\theta_l^{(t)}) \quad (\text{IV.9})$$

Dans M-Step, l'estimation de Θ donnera :

$$\pi_m^{(t+1)} = \sum_{g=1}^{L-1} z_{g,m}^{(t)} h_g \quad (\text{IV.10})$$

$$\sum_{g=0}^{L-1} z_{g,m}^{(t)} h_g \operatorname{sgn} |g - \mu_m^{(t+1)}|^{\beta_m^{(t)} - 1} = 0 \quad (\text{IV.11})$$

$$\alpha_m^{(t+1)} = \left[\frac{\beta_m^{(t)} \sum_{g=0}^{L-1} z_{g,m}^{(t)} h_g \operatorname{sgn} |g - \mu_m^{(t)}|^{\beta_m^{(t)} - 1}}{\sum_{g=0}^{L-1} z_{g,m}^{(t)} h_g} \right]^{1/\beta_m^{(t)}} \quad (\text{IV.12})$$

$$\sum_{g=0}^{L-1} z_{g,m}^{(t)} h_g \left[\frac{1}{\beta_m^{(t+1)}} + \frac{1}{\beta_m^{(t+1)^2}} \Psi(1/\beta_m^{(t+1)}) - \left(\frac{|g - \mu_m^{(t)}|}{\alpha_m^{(t)}} \right)^{\beta_m^{(t+1)}} \log \left(\frac{|g - \mu_m^{(t)}|}{\alpha_m^{(t)}} \right) \right] = 0 \quad (\text{IV.13})$$

$$\text{où, } \operatorname{sgn}(\xi) = \begin{cases} -1 & \text{si } \xi < 0 \\ 1 & \text{si } \xi > 0 \end{cases} \quad \text{et } \Psi(\xi) = \partial \log \Gamma(\xi) / \partial \xi.$$

On remarque que les équations (IV.11) et (IV.13) relatives à l'estimation de μ_m et β_m , respectivement, sont non linéaires. Elles sont résolues par la méthode numérique de Newton-Raphson.

IV.4 Génération de l'image segmentée

Pour présenter l'image segmentée, la réalisation (niveau de gris) optimale $S(u,v)$ pour chaque pixel de coordonnées (u,v) est affectée selon la règle de décision de Bayes

$$S(u,v) = \begin{cases} \mu_1^{t_f} & \text{si } p_1^{(t_f)} = \max_m \{p_m^{(t_f)} : m = 1, \dots, M\} \\ \vdots \\ \mu_M^{t_f} & \text{si } p_M^{(t_f)} = \max_m \{p_m^{(t_f)} : m = 1, \dots, M\} \end{cases} \quad (\text{IV.14})$$

où $p_m^{(t_f)} = \pi_m f_m(g|\theta_m^{(t_f)})$ et $\mu_m^{t_f}$ ($m = 1, \dots, M$) sont les valeurs finales d'estimation du paramètre de la moyenne.

IV.5 Résultats expérimentaux

Afin d'évaluer l'efficacité du modèle proposé dans l'approximation (*ang.* fitting) d'histogramme et la segmentation d'image, un échantillon d'images représentant des radiographies de soudure sont utilisées (voir Fig. IV.3 (a) à (d)). Le nombre de composantes M est choisi par l'utilisateur. Il y a plusieurs algorithmes dédiés au choix automatique du nombre de composantes du mélange, par exemple l'algorithme du message de longueur minimale (*ang.* *minimum message length* (MML)) utilisé dans [139]. Cependant, ici l'objectif est de comparer les résultats de segmentation par les deux modèles GMM et GGMM pour un même nombre de composantes qui est prédéfini *a priori* par l'utilisateur selon le nombre de régions qui lui sont significatives, i.e. selon le nombre de composantes sémantiques. La somme de l'erreur quadratique (SSE) calculée entre l'histogramme estimé et l'histogramme original est utilisée pour mesurer le *fitting* des courbes d'histogrammes

$$SSE = \sum_g \left(h(g) - f(g, \hat{\Theta}) \right)^2 \quad (IV.15)$$

Le critère d'évaluation de segmentation utilisé se base sur la mesure d'homogénéité et est donné par :

$$U = 1 - \sum_{j=1}^M \omega_j \sigma_j^2 / \sigma_T^2 \quad (IV.16)$$

où ω_j , σ_j^2 et σ_T^2 sont, respectivement, le rapport surfacique de la $j^{\text{ème}}$ région de l'image segmentée, les variances de la région j et de l'image totale. Les valeurs de U varient de 0 pour une segmentation totalement erronée à 1 pour une segmentation idéale.

Pour l'initialisation de l'algorithme EM, les modes ont été pris à proportions égales et les moyennes sont fixées à intervalles équidistants sur la plage des niveaux de gris et $\alpha^{(0)}$ et $\beta^{(0)}$ sont pris de sorte que les variances des modes, auxquelles ils sont liés par (IV.7), soient les mêmes et dont la valeur soit égale au maximum du niveau de gris de l'image.

Nous remarquons que les 2^{ème} et 3^{ème} modes pour Fig. IV.3 (a.1) ont des moyennes très proches dans les GMMs, ce qui est traduit par leur mauvaise séparation lors de l'affichage des images segmentées. Pour l'image citée précédemment, la bonne séparation des modes donnée par GGMM permet de mieux apprécier la longueur de la discontinuité longitudinale présente dans la partie centrale du cordon de soudure. On note aussi que la plupart des modes contenus dans les histogrammes donnés par les GMM ne présentent pas des formes similaires à celles des modes correspondants contenus dans les histogrammes originaux, contrairement aux GGMM où les valeurs de SSE sont plus petites comme l'indique Tableau IV.1. Par exemple, dans Fig. IV.3 (b), l'abord de la pièce radiographiée présenté dans la partie inférieure de l'image est mis en évidence par les GGMM contrairement aux GMM où cette région de l'image a été confondue avec le métal de base. Dans Fig. IV.3 (c), pour les GMM, la région du défaut est totalement noyée dans le métal de base ce qui affecte dangereusement les résultats de l'interprétation du film. Quant à Fig. IV.3 (d), la performance des GGMM surpasse celle des

GMM dans l'extraction des défauts de soudures appelés porosités. Par conséquent, les GGMM donnent non seulement une bonne séparabilité des modes mais aussi approximent d'une manière plus précise l'histogramme des niveaux de gris de l'image originale.

Table IV.1 Mesures de performance pour les GMM et les GGMM

Images	# mod. M	GMM-EM			GGMM-EM		
		$\hat{\mu}$	U	SSE ($\times 10^{-4}$)	$\hat{\mu}$	U	SSE ($\times 10^{-4}$)
(a)	4	[31 98 120 218]	0.909	13	[6 45 123 229]	0.923	10
(b)	3	[47 95 130]	0.505	32	[12 48 86]	0.839	19
(c)	2	[105 147]	0.215	11	[87 138]	0.706	5
(d)	3	[12 87 147]	0.780	20	[12 101 29]	0.910	12

IV.5 Conclusion

Donc, à la lumière des résultats donnés par l'indice d'uniformité U et le calcul d'erreurs SSE récapitulés dans Tableau IV.1 et confortés par l'examen visuel des images segmentées et de l'aspect des modes des modèles de mélanges donnés dans Fig. IV.3, ce travail montre que la flexibilité du modèle de mélange basé sur la gaussienne généralisée favorise une restitution plus fiable, par rapport au modèle gaussien, de l'emplacement des différents modes réellement contenus dans l'image d'une part, et permet une approximation plus précise de la forme des modes, d'autre part.

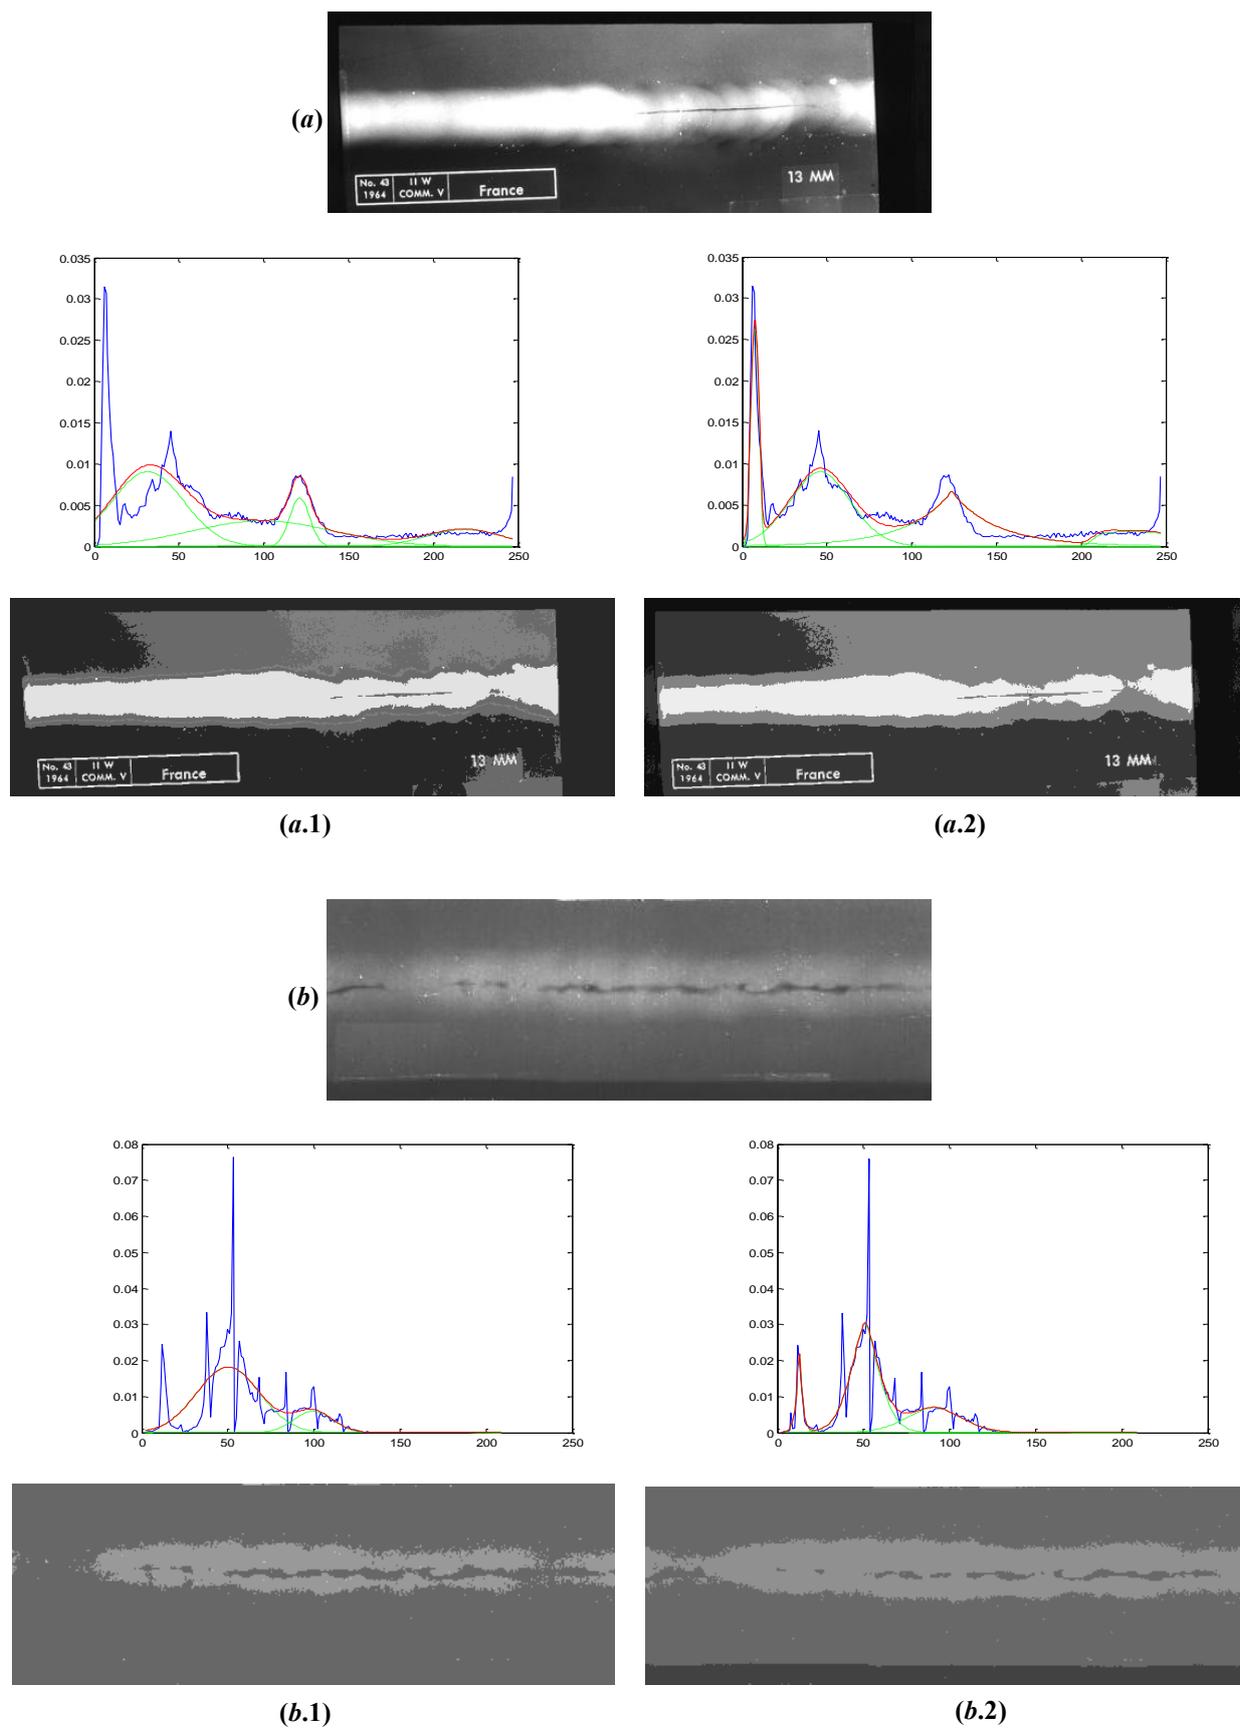


Fig. IV.3 Résultats de la segmentation pour GMM (i.1) et GGMM (i.2) ($i = a, b, c, d$)

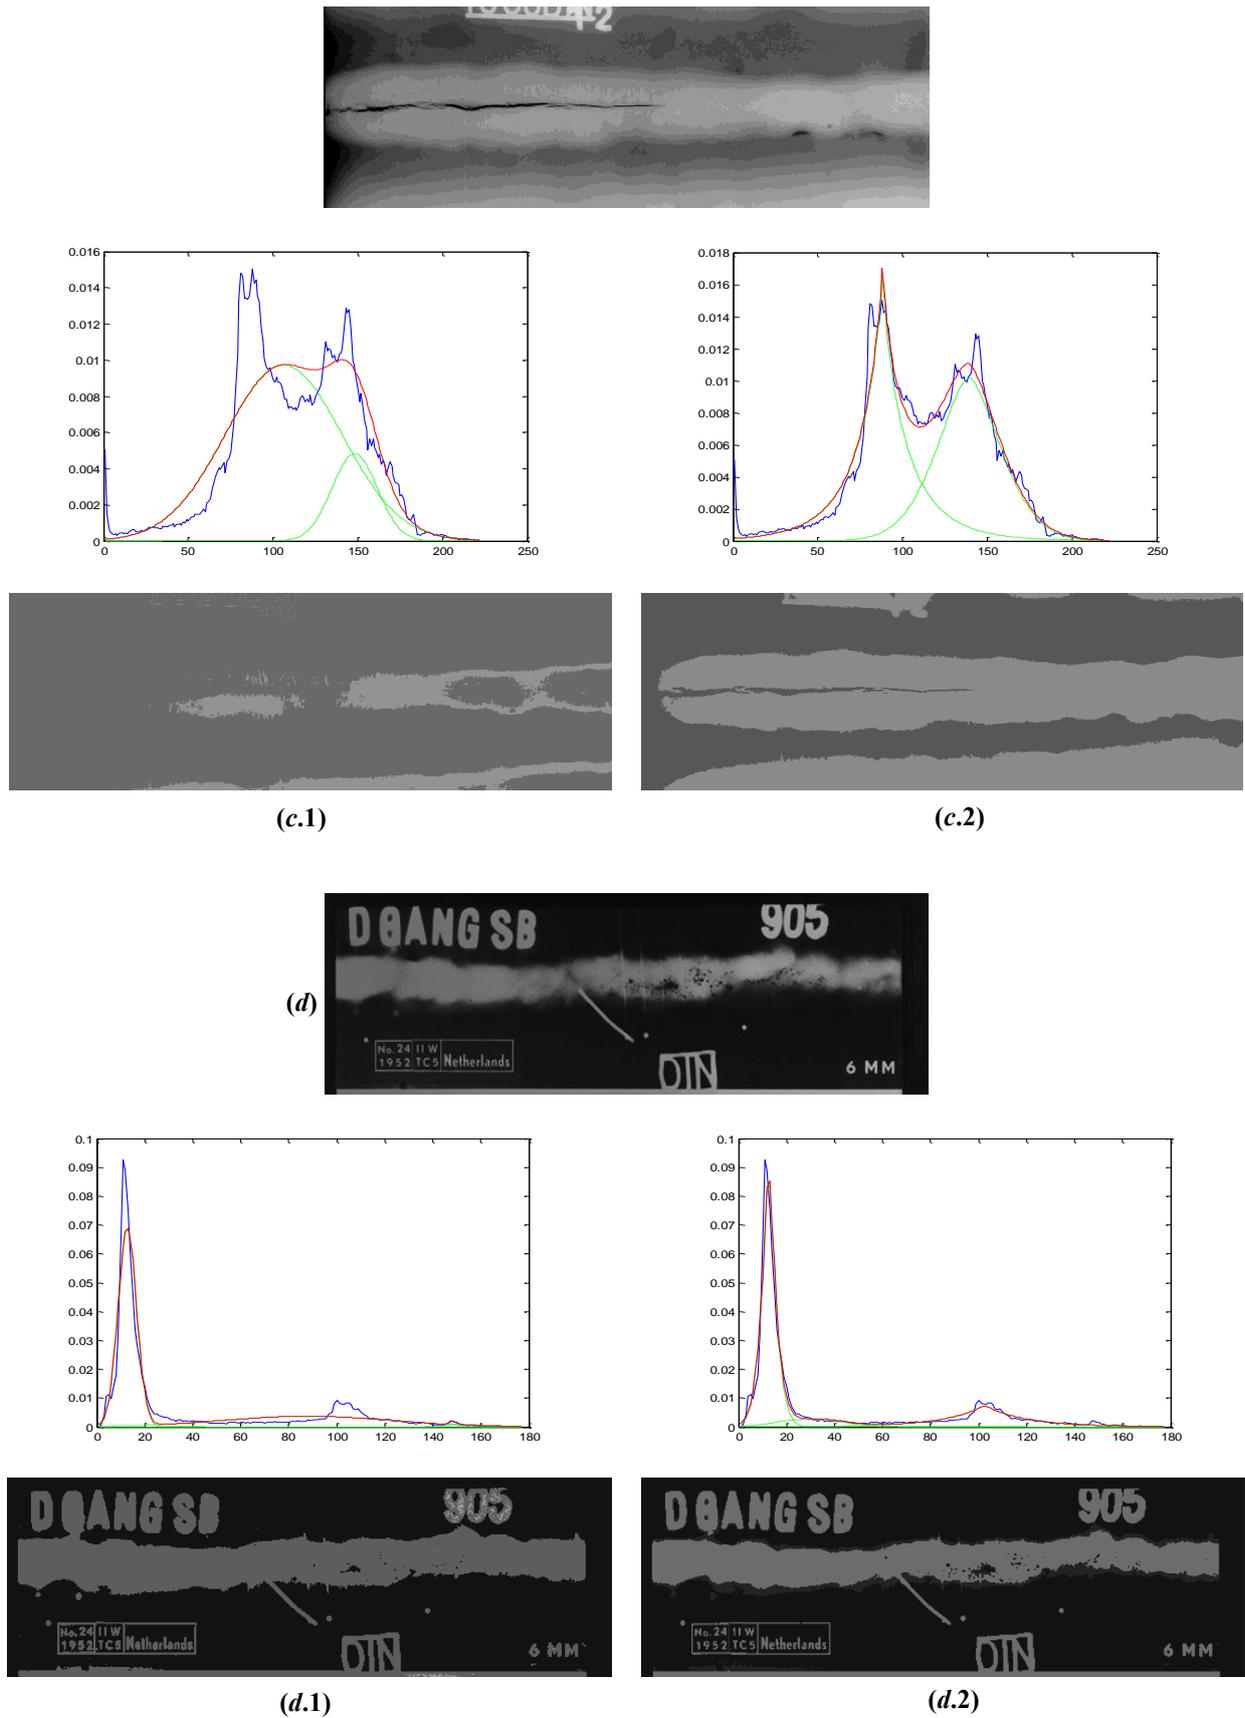


Fig. IV.3 Résultats de la segmentation pour GMM (i.1) et GGMM (i.2) ($i = a, b, c, d$) (suite)

Deuxième partie

INDEXATION DE LA BASE DE DEFAUTS ET RECHERCHE D'IMAGES PAR LE CONTENU

Introduction

Après la détection ou l'extraction du défaut dans l'image radiographique du joint soudé, le problème est alors d'interpréter sa forme. Il est donc question de déterminer des descripteurs efficaces qui permettent de caractériser efficacement ces régions de défauts pour qu'elles deviennent des éléments de classe facilement identifiables. La sélection de descripteurs ou caractéristiques dans un système de recherche d'images est tout à fait semblable à celle dans la classification car un système de recherche d'images par le contenu emploie les mêmes descripteurs d'images utilisés dans la classification [144]. Vu que la mission de l'étape précédente consiste à détecter le défaut comme un objet dans une image binaire représenté par une seule région connexe, alors des descripteurs de forme sont les plus adéquats. Pour cela, deux types de descripteurs sont proposés. L'un consiste dans un vecteur rassemblant des mesures de formes (compacité, élongation etc.), calculées à partir des paramètres de forme (surface, périmètre), et les deux premiers moments invariants de Hu [145]. L'autre est le descripteur de Fourier générique [27]. Ces deux descripteurs sont invariants par rapport aux transformations géométriques usuelles de translation, rotation et changement d'échelle. En se basant sur les caractéristiques de forme des défauts de soudures qui font l'objet de notre étude à savoir la fissure, le manque de pénétration, la porosité et l'inclusion solide, et pour améliorer le taux de récupération du système de recherche, un autre descripteur basé sur une stratégie de fusion entre les deux premiers sera proposé.

Depuis les années 90, la recherche d'images basée sur le contenu (ang. *Content-based image retrieval* (CBIR)) est devenue un secteur activement recherché dans la vision par ordinateur, le multimédia et les bases de données [40]. CBIR est un processus qui consiste à trouver des images semblables dans le contenu visuel à une requête donnée à partir d'une base de données d'image. Il est souvent réalisé par une comparaison des descripteurs de bas niveau, tels que les caractéristiques de couleur, de texture ou de forme, extraites à partir des images elles-mêmes [43]. Bien qu'il existe un grand besoin de l'utilisateur pour une meilleure gestion des données de l'image dans divers domaines, il y a une disparité importante entre les capacités des techniques de CBIR et les besoins des utilisateurs. Ce problème s'appelle le fossé sémantique, un terme utilisé pour exprimer la différence importante entre la similarité calculée à partir des descripteurs de bas niveau et la similarité attendue par les utilisateurs. L'amélioration itérative du procédé de recherche par le retour de pertinence est l'un de mécanismes qui permettent de réduire le fossé sémantique dans les technologies de CBIR en incluant l'utilisateur dans la boucle de recherche [47].

Chapitre 5

Indexation de la base d'images par extraction des caractéristiques de forme

V.1 Introduction

La forme est reconnue comme étant l'une des principales caractéristiques qui décrivent le contenu d'une image. L'étape d'extraction de caractéristiques visuelles est essentielle dans le processus d'indexation d'images. En effet, elle permet de passer de l'image à une description qui soit plus facilement utilisable. Une fois un ensemble de caractéristiques choisi et calculé pour chaque image, seules ces représentations visuelles (ensembles de valeurs de caractéristiques) seront utilisées pour la recherche d'images. Mais comment bien choisir un ensemble de caractéristiques ? En général, la principale qualité d'un descripteur est sa grande capacité de discrimination de sorte qu'il puisse grouper des formes similaires entre elles (i.e. la différence entre les caractéristiques de formes similaires est faible) et séparer les formes dissimilaires dans des groupes différents (i.e. une caractéristique est d'autant plus pertinente que la différence entre les caractéristiques de formes significativement différentes est grande) [25]. En fait, la description idéale doit être stable (robuste au bruit, à la luminosité, etc.), concise (de dimension aussi petite que possible pour permettre un processus de recherche, basé sur un calcul de similarité entre caractéristiques, plus rapide), unique (une image donnée n'a qu'une valeur possible pour chaque caractéristique), accessible et invariante aux transformations géométriques [146]. Généralement, il existe trois méthodes de caractérisation visuelle, fondées respectivement sur l'analyse de la forme, de la couleur et de la texture. Il existe plusieurs méthodes tentant de quantifier la forme comme le ferait l'intuition humaine. Celles-ci peuvent être classées en deux grands types : les méthodes statistiques, basées sur l'étude statistique des mesures que l'on effectue sur les formes à reconnaître, et les méthodes structurelles, qui tentent de représenter la structure physique des formes à reconnaître [147].

Avec les méthodes statistiques, chaque image est représentée par un vecteur caractéristique à n -dimensions. Ces vecteurs sont calculés grâce à des fonctions mathématiques, ou des algorithmes, appelés descripteurs. Parmi les méthodes statistiques, on peut retrouver les caractéristiques géométriques (compacité, élongation, etc.), les moments géométriques (moments invariant de Hu, moments de Zernike, etc.), les transformations (transformée de Fourier, transformée de Mellin-Fourier, etc.) et les signatures (R-signature [148], etc.). En outre, les descripteurs de formes peuvent être scindés en deux catégories principales ; l'une est basée sur les contours et l'autre, sur les régions. Les descripteurs de la première catégorie ne peuvent pas détecter la structure interne de la forme puisqu'ils sont basés sur les contours uniquement. En outre, ces méthodes ne sont pas adaptées aux formes disjointes ou creuses car l'information sur le contour n'est pas disponible.

Le but dans ce chapitre est donc de développer des descripteurs de formes efficaces permettant de caractériser les régions des défauts pour qu'elles soient reconnues par le système de

recherche d'images comme éléments de classe aisément identifiables. En effet, en radiographie industrielle, on peut obtenir des radiogrammes où les images des défauts de soudure, si défaut existe, peuvent avoir diverses résolutions et orientations car le même défaut peut être perçue à partir de plusieurs angles et ce, suivant l'orientation et la distance de l'ouvrage soudé par rapport à la source d'irradiation. A titre d'exemple, une fissure reste une fissure quelles que soient sa grandeur et sa direction et une inclusion est identifiée comme telle en dépit de son emplacement ou sa taille [26]. C'est pourquoi, les descripteurs développés, pour qu'ils soient fiables, doivent d'abord être invariants aux transformations géométriques usuelles de translation, rotation et changement d'échelle.

Dans ce travail, nous proposons deux descripteurs de forme. Le premier contient quelques mesures géométriques de formes et les deux premiers moments invariants de Hu et l'autre n'est autre que le descripteur de Fourier générique [27], lesquels nous allons détailler dans les sections suivantes. Le calcul des descripteurs sera fait sur des ROIs d'images radiographiques de défauts de soudure binarisées, dont un échantillon sera donné à la fin de ce chapitre.

V.2 Descripteur géométrique de forme

V.2.1 Paramètres géométriques de base

Etant donné l'image d'un objet $I = \{f(x, y); 0 \leq x < M, 0 \leq y < N\}$ et R la région de l'image occupée par l'objet, alors $f(x, y) = 1$ si $(x, y) \in R$ et $f(x, y) = 0$ ailleurs. Dans le cas de notre application, cet objet représente le défaut de soudure sur lequel des paramètres géométriques peuvent être mesurés : Surface (A), périmètre (P), centre of gravité $G(\bar{x}, \bar{y})$, angle d'orientation (α), axes principaux d'inertie, largeur (W) et longueur (L) du rectangle minimal exinscrit, surfaces partielles (S_1), (S_2) (S_3) et (S_4) de l'objet délimitées par les axes de symétrie et le rectangle exinscrit, axes semi-majeur et semi-mineur (a, b) de l'ellipse équivalente [26] (voir Fig. V.1).

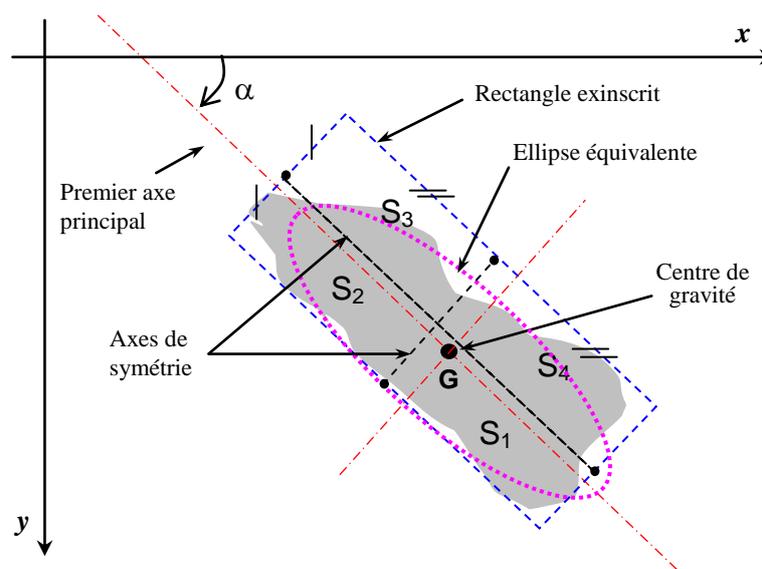


Fig. V.1 Illustration des paramètres géométriques

V.2.2 Descripteur géométrique de forme (GEO)

Les différentes composantes de GEO définies ci-dessous sont invariantes aux transformations géométriques de translation, rotation et changement d'échelle.

Compacité :

La mesure de compacité C représente le ratio entre l'aire de la forme et l'aire du cercle (la forme la plus compacte) ayant le même périmètre

$$C = \frac{4\pi A}{P^2} \quad (\text{V.1})$$

Elongation :

Elle est définie par le rapport entre la longueur et la largeur du rectangle exinscrit

$$E = \frac{L}{W} \quad (\text{V.2})$$

Rectangularité :

Le degré de rectangularité R [149] est égal au ratio entre l'aire de la forme et l'aire de sa boîte englobante minimale :

$$R = \frac{A}{L \times W} \quad (\text{V.3})$$

où L (respectivement W) sont la longueur (respectivement la largeur) du rectangle exinscrit minimal.

Ellipticité :

Le degré d'ellipticité est obtenu à partir du ratio entre l'axe majeur a et l'axe mineur b de l'ellipse équivalente de l'objet [150]:

$$\varepsilon = 1 - \frac{b}{a} \quad (\text{V.4})$$

Cette mesure est invariante à la rotation, la translation et à l'homothétie.

Symétrie :

$$Sym = Sym_H \times Sym_V \quad (\text{V.5})$$

où Sym_V et Sym_H sont données par

$$\begin{cases} Sym_V = \inf(S_3 + S_4, S_1 + S_2) / \sup(S_3 + S_4, S_1 + S_2) \\ Sym_H = \inf(S_2 + S_3, S_1 + S_4) / \sup(S_2 + S_3, S_1 + S_4) \end{cases}$$

Signature normalisée cumulée :

La signature d'une forme est une représentation fonctionnelle 1-D de la frontière et peut consister simplement en la distance entre le centre de gravité et la frontière de l'objet en fonction de l'angle comme il est illustré dans Fig. V.2. La signature polaire est invariante à la translation mais elle dépend de la rotation et le changement d'échelle. L'intégration de la signature normalisée par rapport à $(2\pi \times \text{sa valeur maximale})$ la rend invariante également à la rotation et le changement d'échelle.

$$Sig = \frac{1}{2\pi \max_{\theta}(r(\theta))} \int_0^{2\pi} r(\theta) d\theta \quad (V.6)$$

Moments invariants de Hu [145] :

$$\begin{cases} \Phi_1 = \eta_{20} + \eta_{02} \\ \Phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\ \Phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\ \Phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\ \Phi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ \quad + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ \Phi_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ \quad + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\ \Phi_7 = (3\eta_{21} - \eta_{30})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ \quad + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{cases} \quad (V.7)$$

où $\eta_{pq} = \mu_{pq} / \mu_{00}^{1+(p+q)/2}$ sont les moments centraux normalisés, $p+q = 2,3,\dots$: l'ordre du moment de la fonction image et

$$\begin{bmatrix} \mu_{2,0} = \sum_i^n (x_i - \bar{x})^2 & -\mu_{1,1} = \sum_i^n (x_i - \bar{x})(y_i - \bar{y}) \\ -\mu_{1,1} = \sum_i^n (x_i - \bar{x})(y_i - \bar{y}) & \mu_{0,2} = \sum_i^n (y_i - \bar{y})^2 \end{bmatrix}$$

est la matrice de covariance de l'objet où (x_i, y_i) et n sont respectivement les coordonnées et le nombre des pixels du contour de l'objet.

Teh [151] a défini un ensemble de moments invariants normalisés : $\tilde{\Phi}_i$, $i = 1, \dots, 7$ utilisés dans les problèmes de classification et donnés par :

$$\tilde{\Phi}_i = \log|\Phi_i| / \left[\sum_{i=1}^{i=7} (\log^2|\Phi_i|) \right]^{1/2} \quad (\text{V.8})$$

Dans la suite $\tilde{\Phi}_i$ sera désigné par Φ_i .

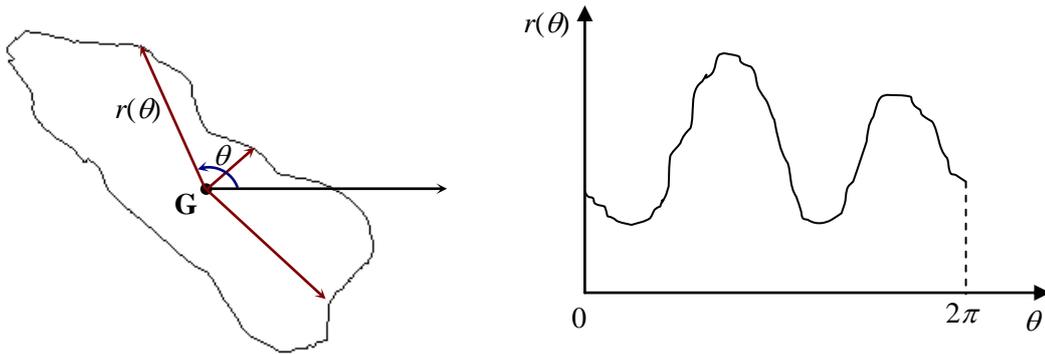


Fig. V.2 Signature polaire

V.2.3 Relation entre GEO et les types des défauts de soudure

Compacité (C) : La valeur de cet attribut est comprise entre 0 et 1. Elle est proche de 0 dans le cas d'une droite et elle est égale à 1 dans le cas d'un cercle parfait. Cet attribut prend des petites valeurs pour les défauts dont la forme est très fine (fissure, manque de fusion) et des valeurs proches de 1 pour les défauts sphéroïdaux (porosité, inclusion de tungstène, inclusion solide sphéroïdale).

Elongation (E) : Cet attribut nous décrit l'espace occupé par le défaut en termes de zone d'encadrement. Des grandes valeurs du rapport entre la longueur et la largeur de cette zone sont caractéristiques des défauts longitudinaux (fissure, manque de fusion, manque de pénétration, soufflure allongée, caniveau, etc.).

Rectangularité (R) : Les valeurs de cet attribut sont comprises entre 0 et 1. Elle est égale à 1 dans le cas d'un rectangle parfait. Cet attribut met en évidence les défauts dont la forme est très proche d'un rectangle. C'est le cas du manque de pénétration.

Ellipticité (ε) : Elle est liée à la direction des axes principaux de la matrice d'inertie du défaut. Sa valeur est comprise entre 0 et 1 et elle est proportionnelle à l'allongement du défaut. Elle tend vers 0 dans le cas d'une porosité.

Symétrie (Sym) : Les valeurs de cet attribut sont comprises entre 0 et 1. La valeur 1 correspond à une forme parfaitement symétrique. L'aspect asymétrique des défauts peut être traduit par des petites valeurs de cet attribut. Ce dernier aspect peut caractériser les inclusions de solide, les soufflures vermiculaires et les fissures radiales.

Signature (Sig) : Sa valeur est comprise entre 0 et 1. Elle tend vers 1 dans le cas d'une porosité.

Moments invariants Φ_1, Φ_2 : Ces moments invariants sont liés directement aux formes des défauts en fournissant des mesures relatives à l'étalement des pixels par rapport au centre de gravité. Dans ce travail, on ne considère que les deux premiers moments invariants Φ_1 et Φ_2 , lesquels sont suffisants pour donner une information sur la répartition des pixels sur la surface du défaut. L'attribut « planéité » n'est autre que le moment Φ_1 .

$$\text{Preuve : } Plan = \iint r^2 dx dy / A^2 \text{ où } \iint r^2 dx dy = \iint ((x - \bar{x})^2 + (y - \bar{y})^2) dx dy = \mu_{20} + \mu_{02} = \mu_{00}^2 (\eta_{20} + \eta_{02}) \\ = \mu_{00}^2 \Phi_1 = A^2 \Phi_1 \text{ c.q.f.d.}$$

Les relations qui lient les types des défauts de soudures choisis dans notre travail, i.e. (fissure (FI), manque de pénétration (MP), porosité (PO), inclusion solide (IS)) à ces descripteurs peuvent être récapitulées dans Tableau V.1.

Tableau V.1 Relations entre défauts de soudure et GEO

Descripteur	Intervalle des valeurs	FI	MP	PO	IS
<i>C</i>	[0 1]	→ 0	< 0.5	→ 1	→ 0.5
<i>E</i>	≥ 1	>> 1	>> 1	→ 1	> 1
<i>R</i>	[0 1]	< 0.5	→ 1	> 0.5	→ 0.5
<i>ε</i>	[0 1]	→ 1	→ 1	→ 0	→ 0.5
<i>Sym</i>	[0 1]	< 0.5	> 0.5	> 0.5	< 0.5
<i>Sig</i>	[0 1]	< 0.5	< 0.5	→ 1	> 0.5
Φ_1 (<i>plan</i>)	> 0	< 0.5	→ 0.5	→ 1	> 0.5
Φ_2	> 0	→ 0.5	< 0.5	→ 0	→ 0

V.2.4 Normalisation du descripteur géométrique de forme

Les différentes caractéristiques dans GEO ont des valeurs qui s'étalent entre 0 et 40. Elles seront normalisées dans l'intervalle [0 1] et ce, pour éviter l'effet « inondant » des grandes valeurs d'attributs par rapport aux plus petites et pour éviter des erreurs numériques possibles causées par un intervalle étendu des valeurs. Cette normalisation a été effectuée, pour chaque donnée (défaut), en utilisant les valeurs maximale et minimale pour chaque caractéristique, comme suit :

$$\tilde{x}_{ni} = \frac{x_{ni} - \min_k (x_{ki})}{\max_k (x_{ki}) - \min_k (x_{ki})}; \quad i = 1, \dots, 8; \quad n, k = 1, \dots, N \quad (\text{V.8})$$

avec N : Nombre d'individus de la base des défauts et $x_{n1} = C_n, x_{n2} = E_n, \dots, x_{n8} = \Phi_{2n}$.

Le choix des valeurs maximum et minimum à utiliser pour normaliser les données est difficile. Le plus évident des choix sont le maximum et le minimum observés à travers tout l'ensemble des données. Cependant, il faut s'assurer que les valeurs max et min représentent réellement les cas extrêmes de l'attribut de forme en question, et qu'elles sont liées à une signification physique de la forme des défauts à caractériser.

V.2.5 Un exemple d'implémentation de GEO

On illustre dans Fig. V.3 quelques paramètres géométriques définis dans §V.2.1, calculés sur une image binaire. Les valeurs des différentes composantes du descripteur sont calculés sur cette dernière et ses transformées par rotation, changement d'échelle et leur combinaison. Il est remarqué que l'invariance par rapport aux transformations géométriques usuelles est vérifiée en globalité comme l'illustre le diagramme en bâtons dans Fig. V.4. La majeure cause de l'erreur est attribuée à la nature numérique de l'image.

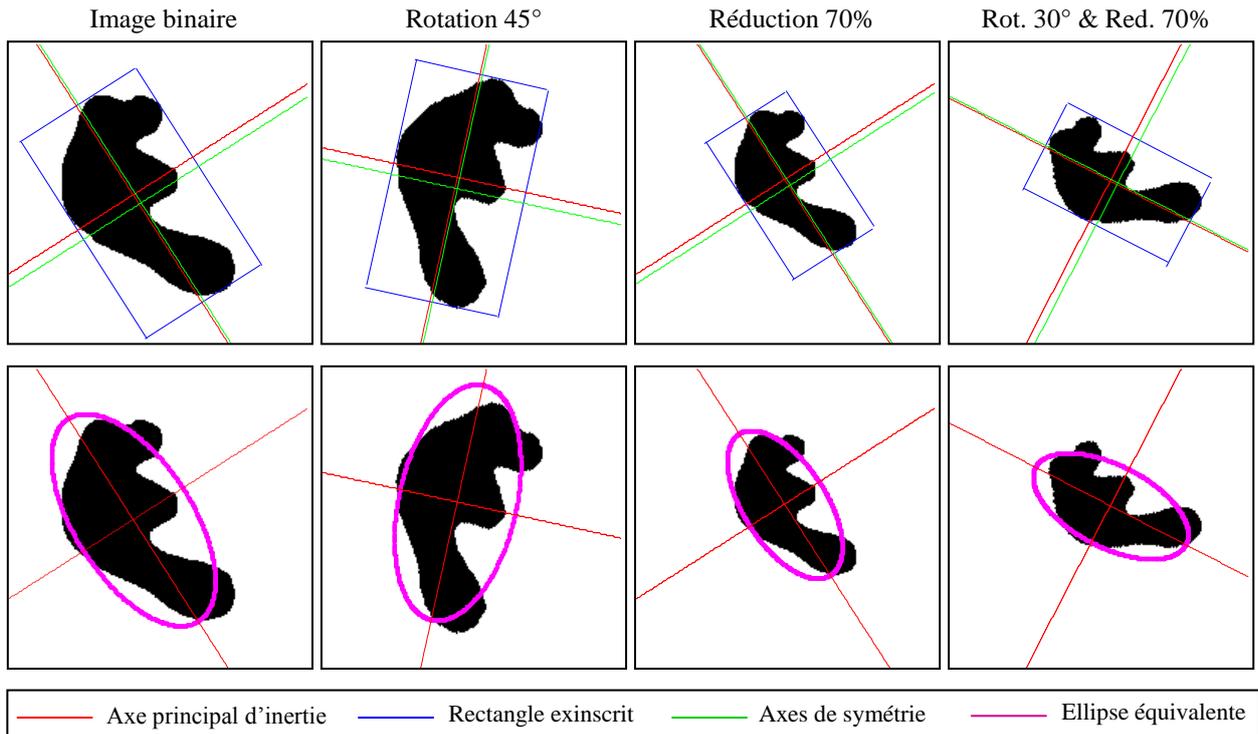


Fig. V.3 Paramètres géométriques implémentés sur une image binaire et ses transformées

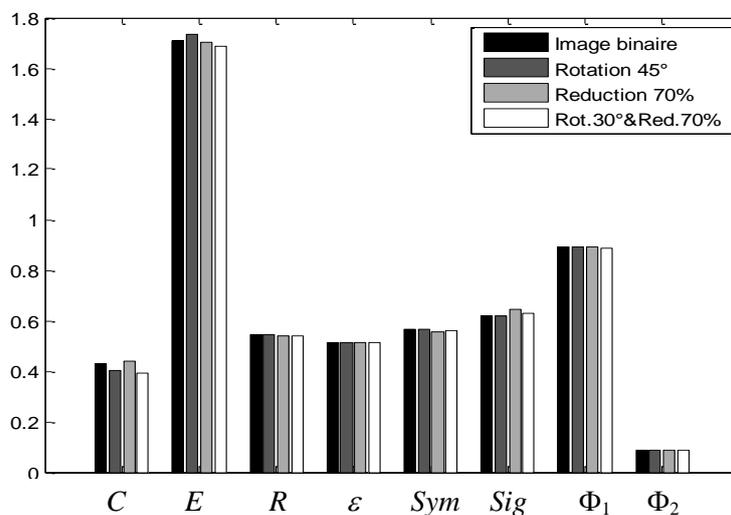


Fig. V.4 GEO non normalisé de l'image binaire ci-dessus et de ses transformées

V.3 Descripteurs de Fourier génériques

V.3.1 Transformée de Fourier polaire

La transformée de Fourier polaire est largement utilisée pour le traitement et l'analyse d'image. L'avantage de l'analyse d'images dans le domaine spectral par rapport l'analyse dans le domaine spatial est qu'il est facile de remédier au problème du bruit qui est courant aux images digitales. En outre, les caractéristiques spectrales d'une image sont souvent plus concises que les caractéristiques extraites du domaine spatial. L'application de la transformée de Fourier 1-D sur une forme suppose une connaissance de l'information de ses frontières. On est donc amené à utiliser la transformée de Fourier basée sur la région, à savoir TF 2-D.

La transformée de Fourier continue et discrète de l'image d'un objet $f(x,y)$ ($0 \leq x < M$, $0 \leq y < N$) sont données par (V.9) et (V.10), respectivement.

$$F(u, v) = \int_x \int_y f(x, y) \times \exp[-j2\pi(ux + vy)] dx dy \quad (V.9)$$

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \times \exp[-j2\pi(ux/M + vy/N)] \quad (V.10)$$

u et v dans (V.10) sont la $u^{\text{ème}}$ et la $v^{\text{ème}}$ fréquence spatiale dans la direction horizontale et verticale, respectivement. La TF 2-D peut être appliqué directement à toute image de forme sans avoir l'information sur les frontières. Cependant, une application directe de TF 2-D sur une forme dans l'espace cartésien pour obtenir des descripteurs de Fourier (DF) n'est pas pratique parce que les caractéristiques extraites par TF 2-D ne sont pas invariantes à la rotation. L'invariance à la rotation d'une forme est importante parce que des formes similaires peuvent avoir perçues sous différentes orientations. Par conséquent, nous considérons l'image de la forme dans les coordonnées polaires en lui appliquant la transformée de Fourier polaire (TFP). La TFP produit des données invariantes à la rotation particulièrement bien adaptées à une extraction des caractéristiques d'orientation d'une manière précise.

Dans ce qui suit, nous étudierons et décrirons deux TFPs. A cet effet, les données $f(x,y)$ et les spectres $F(u,v)$ sont mis en coordonnées polaires. Soit

$$\begin{aligned} x &= r \cos \theta, & y &= r \sin \theta, \\ u &= \rho \cos \psi, & v &= \rho \sin \psi, \end{aligned} \quad (V.11)$$

(r, θ) et (ρ, ψ) sont les coordonnées polaires dans le plan spatial et fréquentiel, respectivement. Les différentiels de x et y sont

$$\begin{aligned} dx &= \cos \theta dr - r \sin \theta d\theta, \\ dy &= \sin \theta dr + r \cos \theta d\theta, \end{aligned} \quad (V.12)$$

Le Jacobien de (V.12) est r . En remplaçant (V.11) et (V.12) dans (V.9) nous obtenons la première TFP (TFP1) exprimée par

$$PF_1(\rho, \psi) = \int_r \int_\theta r f(r, \theta) \times \exp[-j2\pi r \rho \sin(\theta + \psi)] dr d\theta \quad (V.13)$$

La TFP1 discrète est obtenu comme

$$PF_1(\rho_l, \psi_m) = \sum_p \sum_i f(r_p, \theta_i) r_p \exp[-j2\pi r_p \rho_l \sin(\theta_i + \psi_m)] \quad (V.14)$$

où $r_p = p/R$, $\theta_i = i(2\pi/T)$ ($0 \leq i < T$); $\rho_l = l$ ($0 \leq l < R$) et $\psi_m = m\theta_i$. R et T sont la résolution de la fréquence radiale et angulaire, respectivement.

Les coefficients de Fourier polaires acquis sont utilisés pour calculer les descripteurs de Fourier normalisés pour la représentation de forme. TFP1 est le résultat direct de la transformation polaire de (V.9). Cependant, dû à la présence de ψ_m dans l'expression du sinus : $\sin(\theta_i + \psi_m)$, la signification physique de ψ_m n'est pas la $m^{\text{ème}}$ fréquence angulaire. Les caractéristiques extraites par la TFP1 perdent le sens physique dans la direction circulaire. Pour pallier au problème, une TFP modifié (TFP2) est calculée en traitant l'image polaire dans les coordonnées polaires comme une image rectangulaire normale à deux dimensions dans les coordonnées cartésiennes.

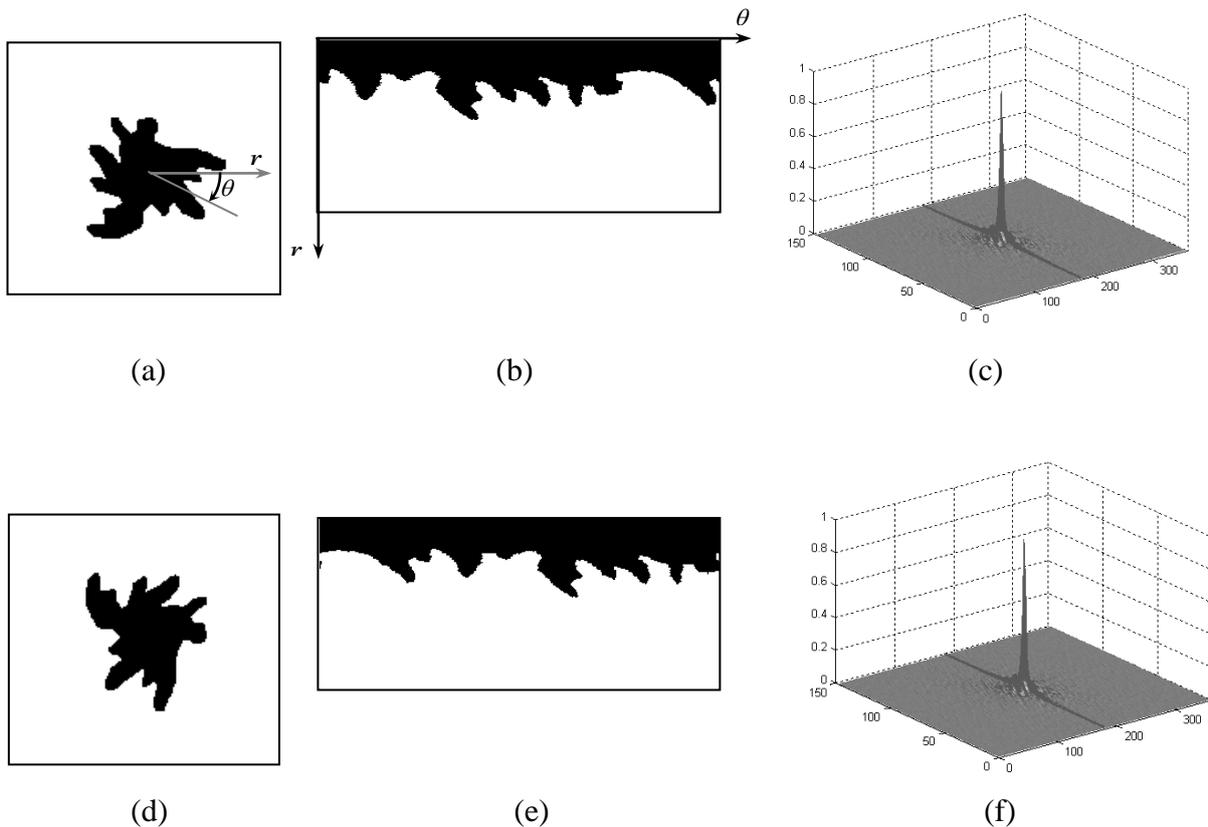


Fig.V.5 (a) et (d) l'objet et l'objet pivoté de $\pi/2$, resp. ; (b) et (e) les images polaires de (a) et (d), resp. dans l'espace cartésien ; (c) et (f) les spectres de Fourier de (b) et (e), resp.

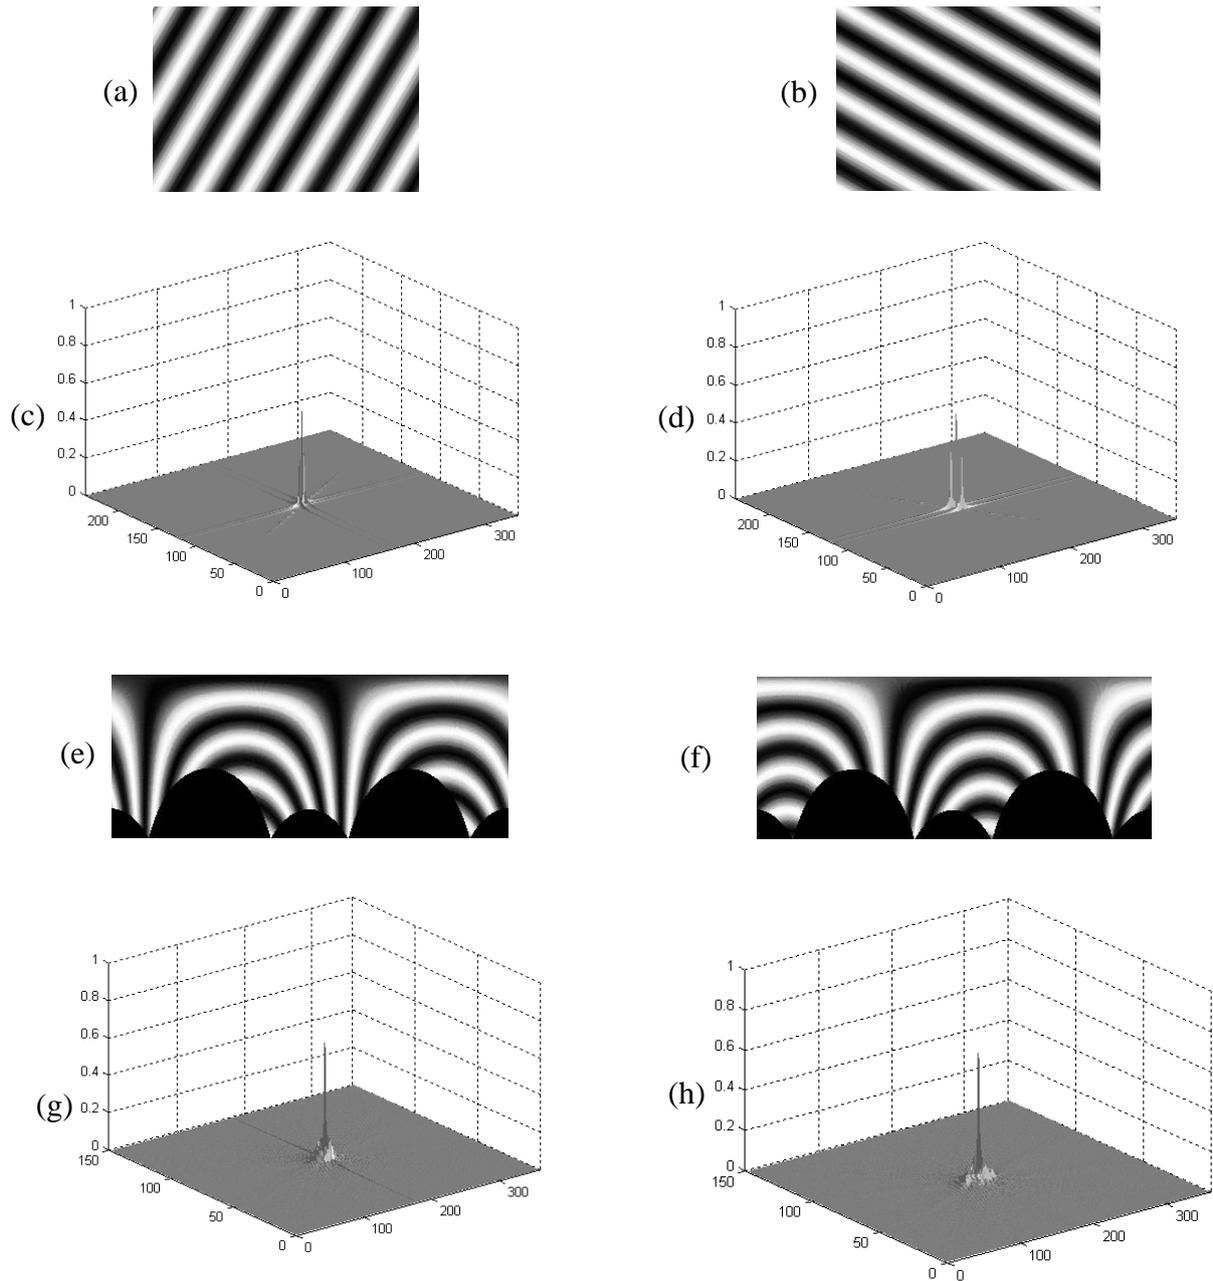


Fig. V.6 (a) et (b) L'image de texture et sa transformée par rotation de $\pi/2$, resp. ; (c) et (d) les spectres de Fourier de (a) et (b), resp. ; (e) et (f) les images polaires dans l'espace cartésien de (a) et (b), resp.; (g) et (h) les spectres de Fourier de (e) et (f), resp.

Fig. V.5 et Fig. V.6 montrent les images polaires rectangulaires. Fig. V.5 (a) et Fig. V.6 (a) sont les images originales dans l'espace cartésien. Fig. V.5 (b) et Fig. V.6 (e) sont les images polaires échantillonnées en trame¹ (*ang.* polar-raster sampled images) tracées dans les coordonnées cartésiennes. Les dimensions de images correspondent au rayon de l'objet/surface,

¹ Autrement dit, ces images sont créées par un échantillonnage circulaire de l'objet/surface dans l'image.

r , et la fréquence d'échantillonnage circulaire (angulaire), θ . Pour Fig. V.5 et Fig. V.6, nous avons pris r_{\max} égal à 150 et $\theta_{\max} = 360$.

L'image polaire de Fig. V.5 (a) est l'image rectangulaire normale. Ainsi, si nous appliquons TF-2D sur cette image rectangulaire, la TF polaire aura une forme similaire à la TF discrète normale 2D donnée par (V.10) dans l'espace cartésien. Par conséquent, la TF polaire modifiée est obtenue comme

$$\mathbf{PF}_2(\rho, \phi) = \sum_r \sum_i f(r, \theta_i) \exp \left[-j2\pi \left(\frac{r}{R} \rho + \frac{i}{T} \phi \right) \right] \quad (\text{V.15})$$

où $0 \leq r < R$ et $\theta_i = i(2\pi/T)$, $0 \leq i < T$; $0 \leq \rho < R$, $0 \leq \phi < T$. R et T sont les résolutions radiale et angulaire. $f(x,y)$ est une fonction binaire. TFP2 admet une forme plus simple que celle de TFP1. En outre, tout simplement, la signification physique de ρ et ϕ sont, respectivement, le nombre de fréquences radiales et angulaires sélectionnées et qui sont similaires à u et v dans (V.10). La détermination de ρ et ϕ est physiquement réalisable, parce que les caractéristiques de forme sont souvent extraites par un nombre réduit de fréquences.

Fig. V.5(b),(e) et Fig. V.6(e),(f) montrent respectivement, les images polaires des objets de Fig. V.5 (a),(d) et Fig. V.6 (a),(b). Leurs spectres de Fourier sont illustrés dans Fig. V.5 (c),(f) et Fig. V.6 (g),(h). Il peut être observé à travers ces figures que la rotation d'une forme dans l'espace cartésien implique un décalage circulaire dans l'espace polaire. Il est à noter aussi que le décalage circulaire ne modifie pas la distribution spectrale dans l'espace polaire, ce qui prévisible à cause de l'invariance du module de la transformée de Fourier à la translation. Le spectre de Fourier polaire est plus concentré autour de l'origine de l'espace polaire. Ceci convient bien à la représentation des formes, parce que pour une représentation efficace de la forme le nombre de caractéristiques des spectres sélectionné pour décrire une forme ne doit pas être très grand. Les coefficients de Fourier polaires calculés $\mathbf{PF}_2(\rho, \phi)$ servent à calculer les descripteurs de Fourier normalisés pour la représentation de forme.

V.3.2 Calcul des descripteurs de Fourier génériques

Etant donné l'image d'un objet $I = \{f(x, y); 0 \leq x < M, 0 \leq y < N\}$. Pour appliquer la TFP, la forme est convertie de l'espace cartésien à l'espace polaire $I_p = \{f(r, \theta); 0 \leq r < R, 0 \leq \theta < 2\pi\}$, R est le rayon maximum de l'objet. L'origine de l'espace polaire est fixée au centre de gravité de la forme, de sorte que la transformée est invariante en translation. L'expression des coordonnées polaires en fonction des coordonnées spatiales est donnée par

$$r = \sqrt{(x - \bar{x})^2 + (y - \bar{y})^2} \quad (\text{V.16})$$

$$\theta = \arctan \frac{y - \bar{y}}{x - \bar{x}} \quad (\text{V.17})$$

La TFP2 est appliquée sur I_p . Les coefficients acquis de la transformation sont invariants à la translation grâce à l'utilisation du centre de gravité comme origine de l'espace polaire. L'invariance à la rotation est effectuée en ignorant l'information de phase dans les coefficients et en retenant seulement les amplitudes de ces derniers. Pour réaliser l'invariance au changement d'échelle, la première valeur d'amplitude est normalisée par rapport à la surface du cercle exinscrit minimal de l'objet, et toutes les autres valeurs d'amplitudes sont normalisées par rapport à l'amplitude du premier coefficient.

Pour récapituler, le descripteur de forme calculé à partir de TFP2 est le descripteur de Fourier générique (ang. *Generic Fourier descriptor* (GFD)) [27]. Il est donné comme suit :

$$\mathbf{GFD} = \left\{ \frac{|PF_2(0,0)|}{\text{Aire}(\text{objet})}, \frac{|PF_2(0,1)|}{|PF_2(0,0)|}, \dots, \frac{|PF_2(0,n)|}{|PF_2(0,0)|}, \dots, \frac{|PF_2(m,0)|}{|PF_2(0,0)|}, \dots, \frac{|PF_2(m,n)|}{|PF_2(0,0)|} \right\} \quad (\text{V.18})$$

où m et n sont le nombre maximal des fréquences radiales et des fréquences angulaires sélectionnées. Dans le cadre de l'évaluation du système de recherche dans le chapitre VI, nous avons pris $m = 6$ et $n = 9$. Ces résolutions s'avèrent suffisantes pour réaliser un compromis entre le temps d'exécution des GFD et les performances du système de recherche. Ces valeurs sont également choisies dans le cas des résultats illustrés dans ce chapitre.

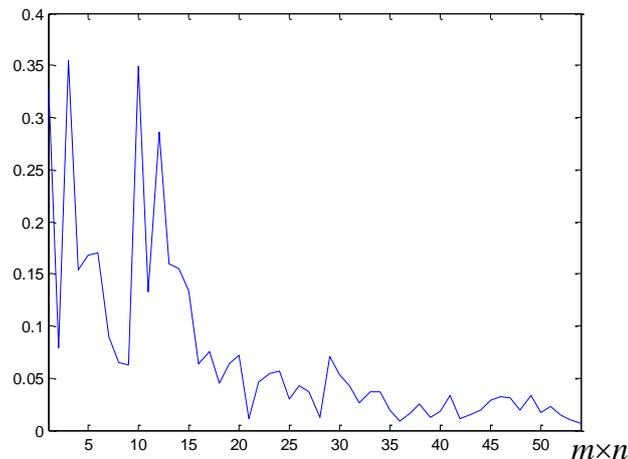


Fig. V.7 Valeurs de GFD pour l'image binaire de Fig. V.3

On donne un exemple de calcul du GFD sur l'image binaire de Fig. V.3. Les signatures de ses transformées géométriques illustrées dans Fig. V.3 sont quasiment identiques à la signature de l'image originale. Les coefficients de corrélation entre la signature de l'image originale et les signatures des images transformées par rotation, réduction et rotation/réduction sont de 0,9999, 0,9999 et 0,9998, respectivement. Fig. V.8 donnent les valeurs des GFD sur d'autres exemples. Il apparaît à travers ces résultats, l'invariance dudit descripteur par rapport aux transformations géométriques de translation, de rotation et de changement d'échelle. L'avantage de ces descripteurs est qu'ils détectent le contenu intérieur d'une forme aussi bien que ses caractéristiques de frontière.

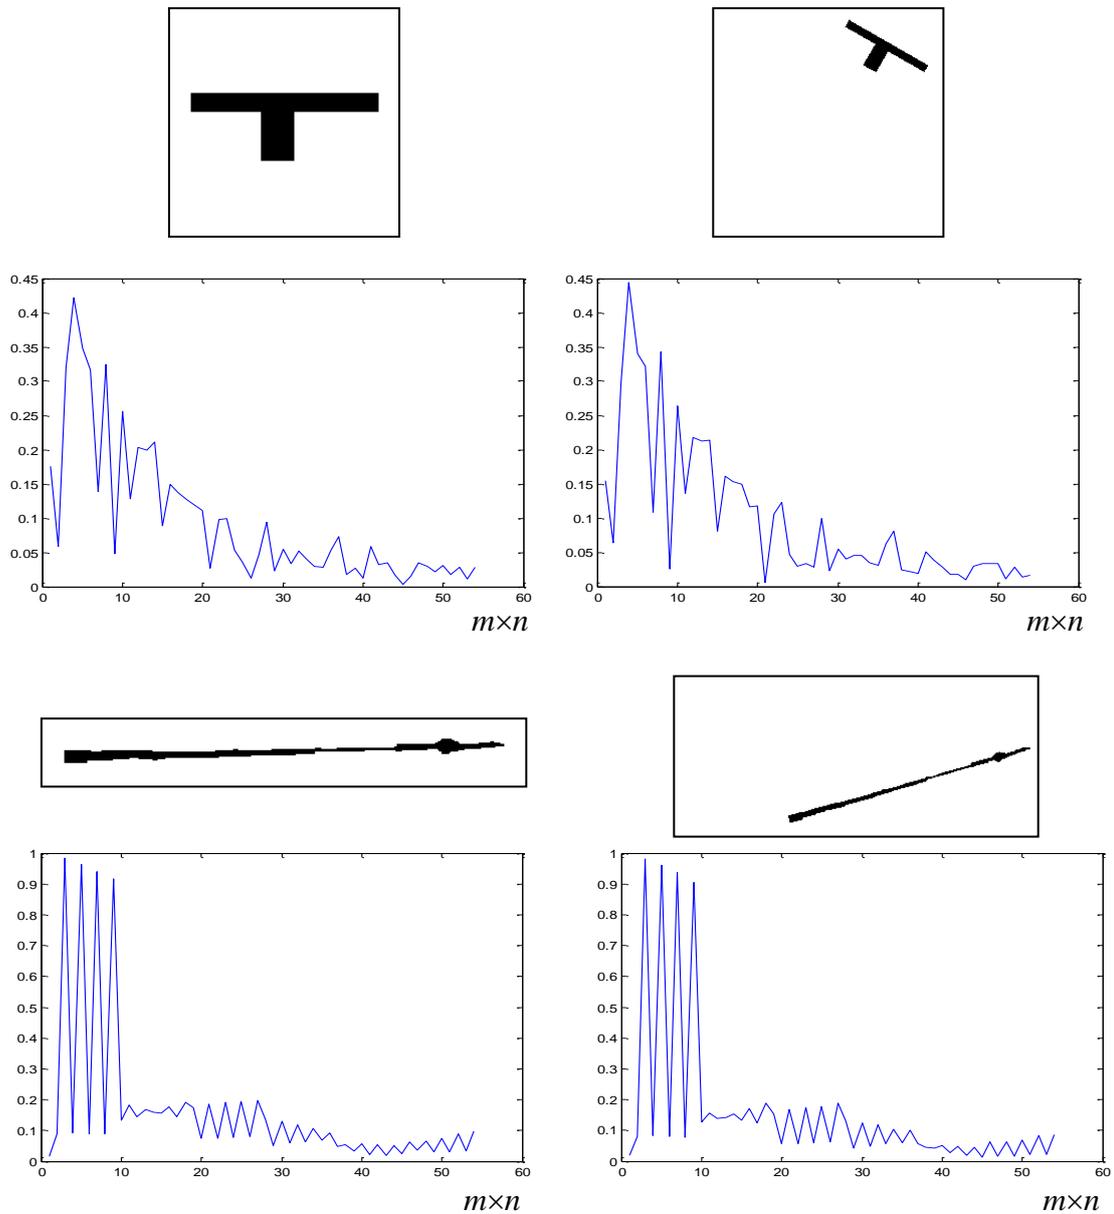


Fig. V.8 Exemples de calcul de GFD

V.4 Calcul des descripteurs sur quelques images de défauts de soudures

Plus de 340 régions de défauts, représentées par leurs versions binarisées après seuillage, sont extraites des films radiographiques de soudures fournis par l'institut international de soudage (IIW), représentant quatre classes de défauts de soudures de 86 éléments chacune : fissure (FI), manque de pénétration (MP), porosité (PO) et inclusion solide (IS). Quelques exemples de ces défauts sont illustrés dans Fig. V.9. On donne dans Fig. V.10 et Fig.11 les valeurs de GEO et GFD, respectivement, calculées sur ces défauts.

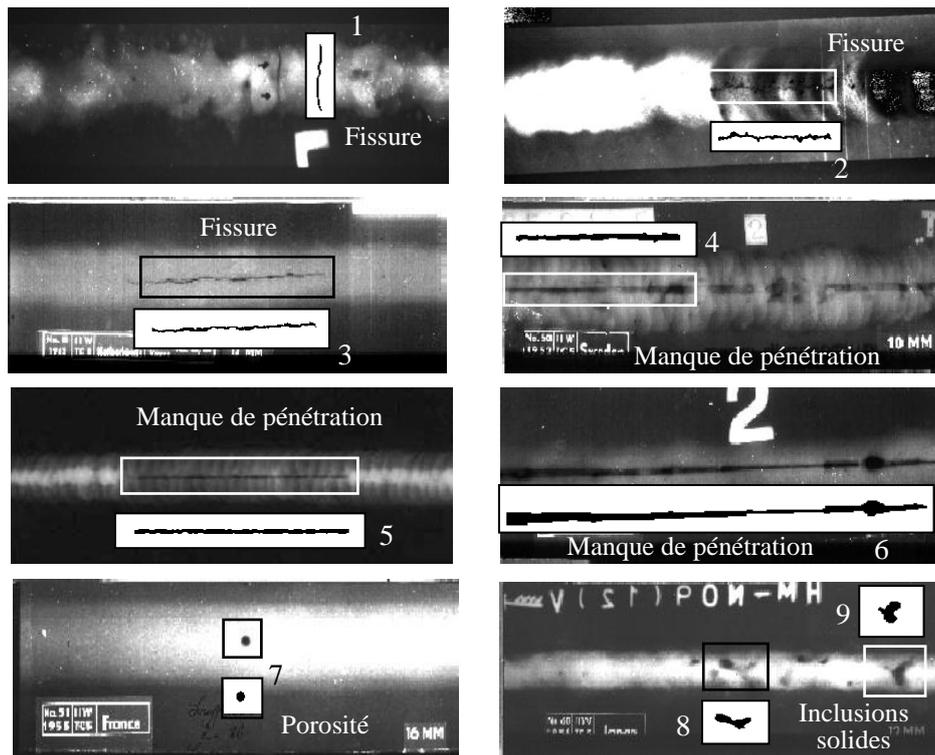


Fig. V.9 Exemples de ROIs représentant des défauts de soudures (numérotés de 1 à 9) et leurs versions binarisées

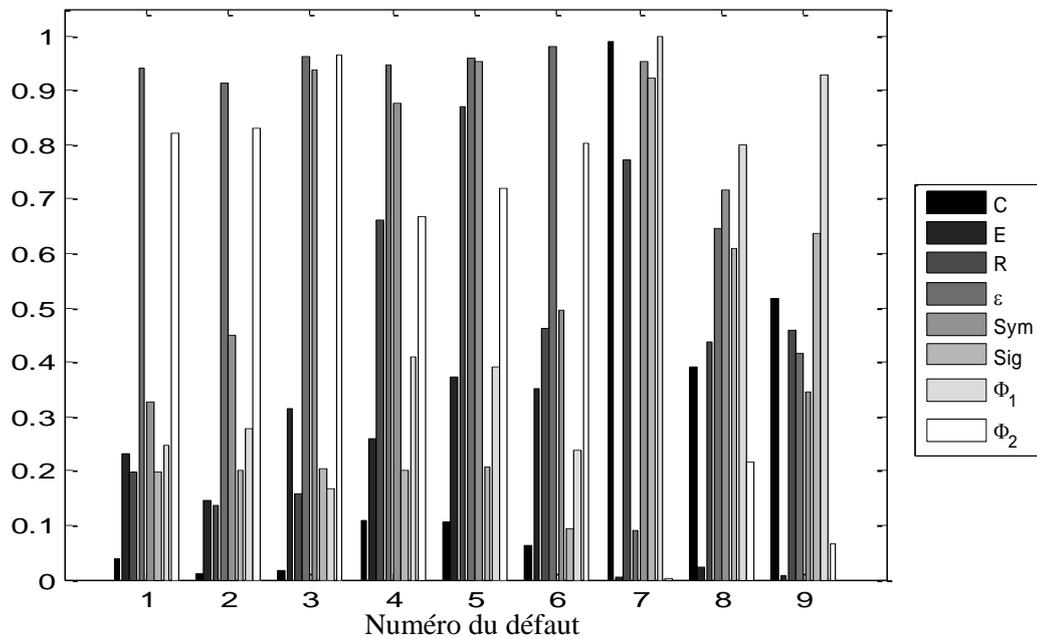


Fig. V.10 Valeurs de GEO pour les défauts donnés dans Fig. V.9

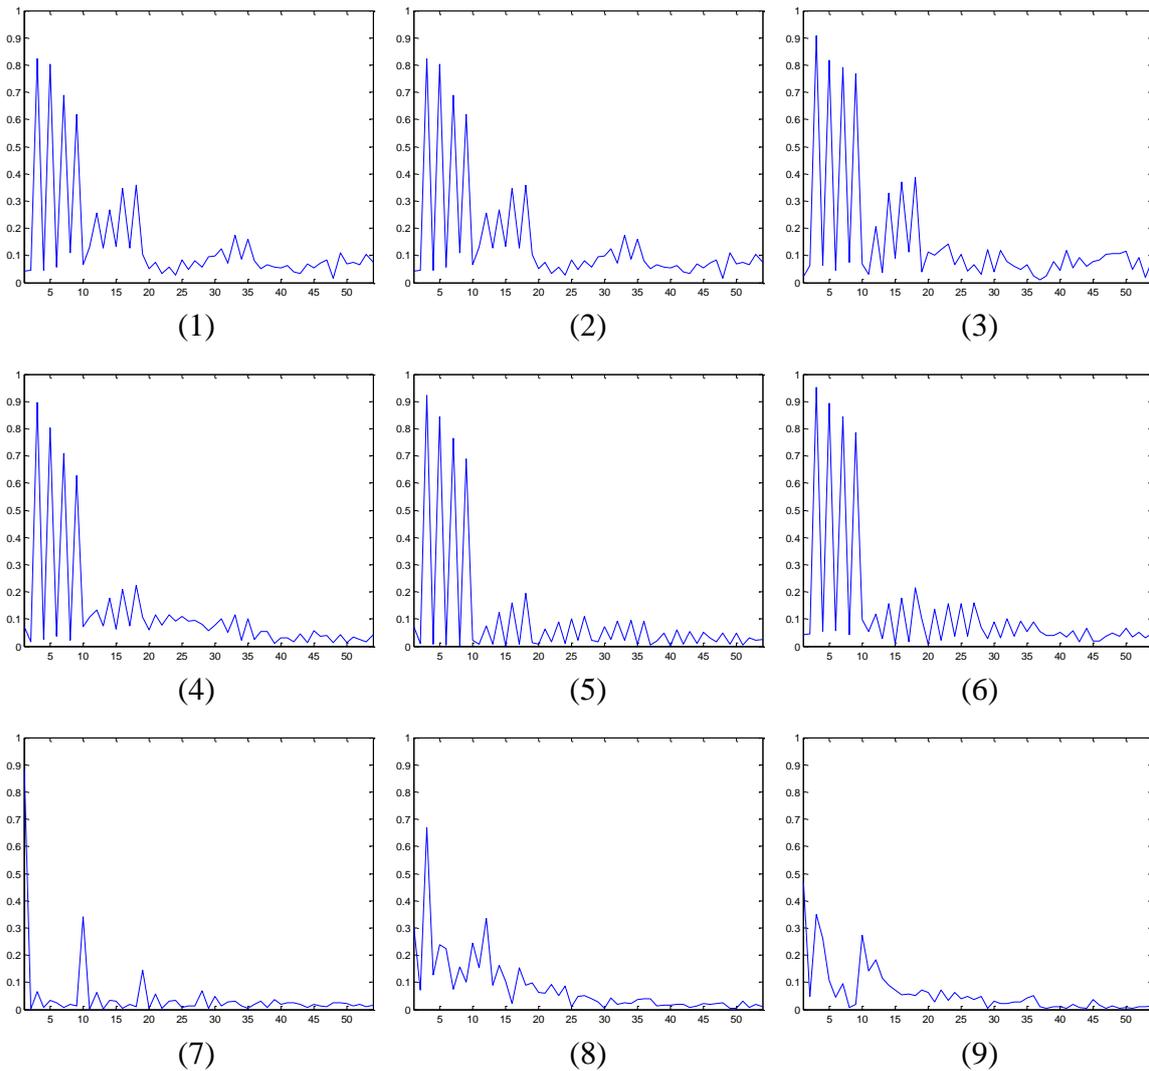


Fig. V.11 Valeurs de GFD pour les défauts donnés dans Fig. V.9

V.5 Conclusion

Nous avons proposé dans ce chapitre, deux descripteurs GEO et GFD. Leurs propriétés et leurs implémentations ont été détaillées. Nous avons souligné avec des résultats à l'appui sur l'invariance de ces attributs par rapport aux transformations géométriques usuelles vue l'utilité de cette propriété dans le cas de notre application comme il a été cité dans l'introduction de ce chapitre. Les valeurs du vecteur d'attributs ainsi calculées ont été normalisées pour GEO, tandis que la normalisation est inhérente à la construction des GFD. Les composantes de GEO sont choisies parmi tant d'autres sur la base de leur pouvoir discriminant et leurs relations directes avec les différents types des défauts de soudure étudiés comme il a été mentionné dans §V.2.3. Par contre, nous avons opté pour les GFD, non pour les caractéristiques de nos images, mais pour être connus pour leur puissance dans la description des formes pleines en général.

Chapitre 6

Recherche d'images par le contenu et retour de pertinence

VI.1 Retour de pertinence : principe et état de l'art

Le retour de pertinence, tel montré dans Fig. VI.1, est un mécanisme basé sur l'interaction Homme-Machine. Initialement, un utilisateur soumet une requête (image de défaut que l'on désire rechercher) pour lancer la recherche. Le système recherche des images à partir de la base des données en utilisant un calcul de similarité. Les images de retour sont similaires à la requête par leurs descripteurs visuels de bas niveau mais peuvent ne pas correspondre à la perception de l'utilisateur. L'utilisateur évalue donc ces images en affectant à chacune d'elles un degré de pertinence par rapport à la requête et relance le système. Le critère de similarité est alors ajustée et de nouvelles images sont renvoyées et visualisées. Alors l'utilisateur évalue de nouveau ces dernières images et réinjecte au système la nouvelle évaluation. Ce cycle (recherche (machine) / évaluation (Homme)) est ainsi répété jusqu'à ce que l'utilisateur arrête la rétroaction en jugeant que les résultats renvoyés sont satisfaisants. Les techniques de retour de pertinence (*ang.* Relevance Feedback (RF)) trouvent leur origine dans les années 1970 avec notamment les travaux de [Rocchio](#) [152] sur le retour explicite de pertinence appliqué à la recherche de documents et qui peut être illustrée par la formule suivante

$$q' = \alpha q + \beta \left(\frac{1}{N_{R'}} \sum_{i \in D_{R'}} D_i \right) - \gamma \left(\frac{1}{N_{N'}} \sum_{i \in D_{N'}} D_i \right) \quad (\text{VI.1})$$

où α , β et γ sont des constantes appropriées et $N_{R'}$ et $N_{N'}$ sont le nombre de documents dans les bases de données $D_{R'}$ et $D_{N'}$, respectivement.

C'est-à-dire, pour une requête initiale donnée, et un ensemble de documents pertinents $D_{R'}$ et de documents non pertinents $D_{N'}$ donnés par l'utilisateur, la nouvelle requête optimale, q' , est celle qui s'est approchée aux points d'exemples positifs et s'est éloignée des points d'exemples négatifs (voir à titre illustratif Fig. VI.2).

Principalement, les méthodes de retour de pertinence sont fondées sur deux approches : statistique et géométrique. Les méthodes statistiques sont à leur tour subdivisées en deux approches : l'approche modélisation de la pertinence, (exp. [153]) et l'approche par classification (exp. [154]). L'approche modélisation de la pertinence affecte à chaque image de la base une valeur, généralement une probabilité, traduisant son adéquation à la requête. La densité de probabilité construite pour l'ensemble des images de la base est itérativement mise à jour par l'interaction avec l'utilisateur [155]. L'approche par classification aborde le problème de bouclage de pertinence sous l'angle de la séparation des images pertinentes et non-pertinentes dans les espaces d'attributs.

Pour l'approche géométrique du retour de pertinence, la recherche-par-similarité (ou recherche-par-l'exemple) repose sur deux concepts majeurs, la requête et la fonction de similarité. Deux

tendances peuvent être distinguées au sein de cette approche, la première correspond à la mise à jour de la requête alors que la seconde correspond à la modification de la mesure de similarité. Ces deux tendances sont parfois combinées. Du point de vue de l'adaptation de la fonction de similarité, des heuristiques peuvent être utilisées. L'heuristique la plus répandue concerne la dispersion des valeurs des attributs (exp. [156,157]): un attribut discriminant est caractérisé par une faible variance sur les images pertinentes. Une deuxième heuristique possible porte sur la notion de rang (exp. [158]): un attribut discriminant tend à classer les images pertinentes parmi les résultats les plus proches de la requête et inversement pour les images non-pertinentes. Il est cependant possible d'opposer aux méthodes heuristiques des techniques géométriques de retour de pertinence dites « basées optimisation » qui reposent sur l'optimisation d'un critère mathématique [39,42,45].

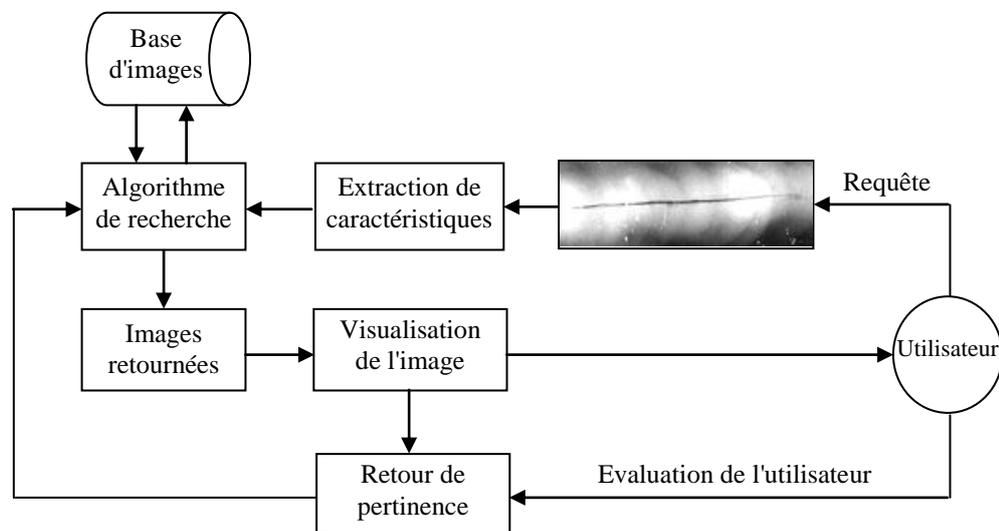


Fig. VI.1 Structure du système de Recherche des défauts de soudure par Retour de Pertinence

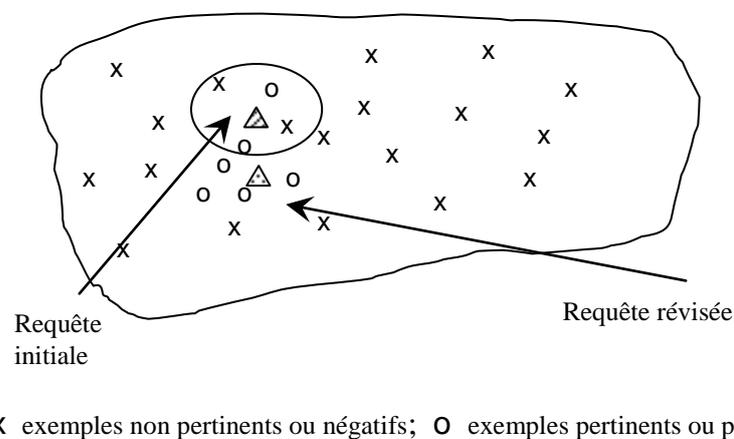


Fig. VI.2 Mise à jour de la requête dans le retour de pertinence

VI.2 Le modèle MindReader et le modèle de Rui

Le système MindReader de Ishikawa et al. [39] propose un schéma de retour de pertinence « basé optimisation » pour la mise à jour conjointe de la requête et de la fonction de similarité. Ce schéma repose sur la minimisation des distances entre le vecteur requête et les exemples positifs. La métrique utilisée est une distance quadratique généralisée. Si \vec{q} est le vecteur requête et \vec{x}_m est le vecteur de la $m^{\text{ième}}$ image cible, la distance quadratique généralisée est notée

$$d_m = (\vec{x}_m - \vec{q})^T W (\vec{x}_m - \vec{q}) \quad (\text{VI.2})$$

où W est une matrice pleine symétrique satisfaisant la contrainte : $\det(W) = 1$.

Supposons que l'utilisateur identifie N images pertinentes parmi celles retrouvées par le système et leur associe un degré de pertinence ($\pi_n > 0$ pour la $n^{\text{ième}}$ image pertinente), alors cela revient à résoudre un problème d'optimisation sous contraintes

$$J_1 = \sum_{n=1}^N \pi_n (\vec{x}_n - \vec{q})^T W (\vec{x}_n - \vec{q}) \quad (\text{VI.3})$$

où les solutions optimales pour la requête et les éléments de W peuvent être obtenus en utilisant les multiplicateurs de Lagrange.

MindReader adopte une description mono-vectorielle de l'image, i.e. que les vecteurs correspondants aux différents attributs sont concaténés en un unique descripteur (modèle plat).

La méthode de Rui [42] repose, au contraire, sur un modèle hiérarchique séparant les différents attributs en I caractéristiques. En notant d_{ni} la distance quadratique généralisée obtenue entre le vecteur requête \vec{q}_i et la $n^{\text{ième}}$ image pertinente \vec{x}_{ni} pour la $i^{\text{ème}}$ caractéristique, la distance hiérarchique totale D_n vaut :

$$D_n = U(d_{ni}) \quad (\text{VI.4})$$

avec

$$d_{ni} = (\vec{x}_{ni} - \vec{q}_i)^T W_i (\vec{x}_{ni} - \vec{q}_i) \quad (\text{VI.5})$$

$U(\cdot)$ est la fonction combinant les différentes caractéristiques. Rui choisit d'utiliser une combinaison linéaire des distances, i.e. que $U(\cdot)$ consiste en un vecteur de paramètres donné par $\vec{u} = [u_1, \dots, u_I]^T$. Le problème se ramène ensuite à la minimisation du critère sous contraintes suivant :

$$J = \sum_{i=1}^I u_i \sum_{n=1}^N \pi_n (\vec{x}_{ni} - \vec{q}_i)^T W_i (\vec{x}_{ni} - \vec{q}_i) \quad (\text{VI.6})$$

avec les conditions suivantes :

$$\sum_{i=1}^I 1/u_i = 1 \text{ et } \det(W_i) = 1; \quad i = 1, \dots, I \quad (\text{VI.7})$$

L'optimalité de la fonction objective J sera réalisée en minimisant les distances entre la requête idéale et tous les exemples positifs de rétroaction. Le degré de pertinence π_n de chaque exemple est choisi par l'utilisateur. La fonction objective J est linéaire en \vec{u} et W_i et quadratique en \vec{q}_i . De nouveau, nous employons des multiplicateurs de Lagrange pour résoudre un problème d'optimisation sous contraintes, par le calcul de \vec{q}_i , W_i et \vec{u} qui minimisent la quantité L donnée par :

$$L = J - \lambda \left(\sum_{i=1}^I \frac{1}{u_i} - 1 \right) - \sum_{i=1}^I \lambda_i (\det(W_i) - 1) \quad (\text{VI.8})$$

VI.2.1 Solution optimale pour \vec{q}_i

Pour obtenir la solution optimale pour \vec{q}_i , nous considérons la dérivée partielle de L par rapport à \vec{q}_i :

$$\begin{aligned} \frac{\partial L}{\partial \vec{q}_i} &= u_i \left[\pi_1 \frac{\partial}{\partial \vec{q}_i} [(\vec{x}_{1i} - \vec{q}_i)^T W_i (\vec{x}_{1i} - \vec{q}_i)] + \dots + \pi_N \frac{\partial}{\partial \vec{q}_i} [(\vec{x}_{Ni} - \vec{q}_i)^T W_i (\vec{x}_{Ni} - \vec{q}_i)] \right] \\ &= u_i \left[\pi_1 (-2(\vec{x}_{1i} - \vec{q}_i)^T W_i) + \dots + \pi_N (-2(\vec{x}_{Ni} - \vec{q}_i)^T W_i) \right] \\ &= -2u_i W_i \left[(\pi_1 \vec{x}_{1i}^T + \dots + \pi_N \vec{x}_{Ni}^T) - (\pi_1 + \dots + \pi_N) \vec{q}_i^T \right] \end{aligned} \quad (\text{VI.9})$$

En posant l'équation ci-dessus égale à zéro, nous aurons la solution optimale pour \vec{q}_i ,

$$\vec{q}_i^{T*} = \vec{\pi}^T X_i / \sum_{n=1}^N \pi_n \quad (\text{VI.10})$$

où X_i est la matrice, de dimension $N \times K_i$ pour la caractéristique i dont la dimension est K_i , formée en empilant les N vecteurs transposés correspondant aux exemples positifs annotés.

L'équation ci-dessus correspond à la formulation intuitive d'un vecteur requête optimal qui n'est autre qu'une moyenne pondérée des exemples positifs pour chaque caractéristique i .

VI.2.2 Solution optimale pour W_i

Avant d'explorer comment trouver la solution optimale de W_i , nous notons que la contrainte $\det(W_i) = 1$ peut être réécrite comme

$$\sum_{r=1}^{K_i} (-1)^{r+s} w_{i_{rs}} \det(W_{i_{rs}}) = 1, \quad r, s = 1, \dots, K_i \quad (\text{VI.11})$$

où $\det(W_{i_{rs}})$ est le $(rs)^{\text{ème}}$ mineur de W_i , et $W_i = [w_{i_{rs}}]$.

En outre, cette équation peut être réécrite comme :

$$\sum_{r=1}^{K_i} \sum_{s=1}^{K_i} (-1)^{r+s} w_{i_{rs}} \det(W_{i_{rs}}) = K_i \quad (\text{VI.12})$$

Pour obtenir la solution optimale de W_i , nous annulons la dérivée partielle de L par rapport à $w_{i_{rs}}$, cela revient à écrire

$$\frac{\partial L}{\partial w_{i_{rs}}} = u_i \sum_{n=1}^N \pi_n (x_{ni_r} - q_{i_r})(x_{ni_s} - q_{i_s}) - \lambda_i (-1)^{r+s} \det(W_{i_{rs}}) = 0 \quad (\text{VI.13})$$

$$\det(W_{i_{rs}}) = \frac{u_i \sum_{n=1}^N \pi_n (x_{ni_r} - q_{i_r})(x_{ni_s} - q_{i_s})}{\lambda_i (-1)^{r+s}} \quad (\text{VI.14})$$

Définissons la matrice W_i^{-1} comme la matrice inverse de W_i . Pour calculer la composante $w_{i_{rs}}^{-1}$, nous utilisons la méthode du déterminant pour l'inversion de la matrice. Nous aurons

$$w_{i_{rs}}^{-1} = \frac{(-1)^{r+s} \det(W_{i_{rs}})}{\det(W_i)} \quad (\text{VI.15})$$

Sachant que $\det(W_i) = 1$, nous trouvons

$$w_{i_{rs}}^{-1} = \frac{u_i}{\lambda_i} \sum_{n=1}^N \pi_n (x_{ni_r} - q_{i_r})(x_{ni_s} - q_{i_s}) = \frac{u_i \sum_{n=1}^N \pi_n}{\lambda_i} C_{i_{rs}} \quad (\text{VI.16})$$

où $C_{i_{rs}} = \sum_{n=1}^N \pi_n (x_{ni_r} - q_{i_r})(x_{ni_s} - q_{i_s}) / \sum_{n=1}^N \pi_n$, n'est autre que le $(r,s)^{\text{ème}}$ élément de la matrice pondérée de covariance (C_i) de X_i . (VI.16) peut être écrite dans une forme matricielle comme

$W_i^{-1} = \frac{1}{\gamma} C_i$ où $\gamma = \lambda_i / \left(u_i \sum_{n=1}^N \pi_n \right)$. Nous obtenons $C_i = \gamma W_i^{-1} \Rightarrow \det(C_i) = \gamma^{K_i} \det(W_i^{-1})$;

mais puisque $\det(W_i^{-1}) = 1$, alors $\gamma = (\det(C_i))^{1/K_i} = \gamma^{K_i} \det(W_i^{-1})$.

Finalement, la matrice de pondération intra-caractéristique optimale est donnée par

$$W_i^* = \gamma C_i^{-1} = (\det(W_i^{-1}))^{1/K_i} C_i^{-1} \quad (\text{VI.17})$$

VI.2.3 Solution optimale pour u_i

Pour obtenir la solution optimale pour u_i , nous annulons la dérivée partielle de L par rapport à u_i :

$$\frac{\partial L}{\partial u_i} = \left[\pi_1 (\bar{x}_{1i} - \bar{q}_i)^T W_i (\bar{x}_{1i} - \bar{q}_i) + \dots + \pi_N (\bar{x}_{Ni} - \bar{q}_i)^T W_i (\bar{x}_{Ni} - \bar{q}_i) \right] + \frac{\lambda}{u_i^2} = 0; \quad \forall i \quad (\text{VI.18})$$

Multiplions les deux cotés de l'équation par u_i et récapitulons sur i . Nous aurons

$$\sum_{i=1}^I u_i \sum_{n=1}^N \pi_n (\bar{x}_{ni} - \bar{q}_i)^T W_i (\bar{x}_{ni} - \bar{q}_i) + \lambda \sum_{i=1}^I \frac{1}{u_i} = 0 \quad (\text{VI.19})$$

Puisque $\sum_{i=1}^I \frac{1}{u_i} = 1$, la valeur optimale de λ est

$$\lambda^* = - \sum_{i=1}^I u_i f_i \quad (\text{VI.20})$$

où $f_i = \sum_{n=1}^N \pi_n (\bar{x}_{ni} - \bar{q}_i)^T W_i (\bar{x}_{ni} - \bar{q}_i)$.

Après la substitution de (VI.20) dans (VI.18), nous avons

$$u_i^2 f_i = \sum_{j=1}^I u_j f_j \quad (\text{VI.21})$$

A partir de (VI.18), nous savons aussi que $\lambda = u_1^2 f_1 = \dots = u_i^2 f_i = \dots = u_j^2 f_j = \dots = u_l^2 f_l$

C'est à dire,

$$u_j = u_i \sqrt{\frac{f_i}{f_j}}, \quad \forall j \quad (\text{VI.22})$$

Après avoir substitué cette équation dans (VI.21), alors le vecteur de pondération inter-caractéristique optimal u_i^* s'exprime comme

$$u_i^2 f_i - \left(\sum_{j=1}^I \sqrt{f_i f_j} \right) u_i = 0 \quad (\text{VI.23})$$

$$u_i^* = \sum_{j=1}^I \sqrt{\frac{f_j}{f_i}} \quad (\text{VI.24})$$

La solution optimale trouvée accorde donc plus de poids aux caractéristiques conduisant aux faibles distances totales, i.e. aux caractéristiques considérées comme les plus discriminantes.

VI.2.4 Solutions optimales pour MinReader

D'une manière analogue, on obtient dans le système MindReader les solutions optimales suivantes : pour $\bar{q} : \bar{q}^{T*} = \bar{\pi}^T X / \sum_{n=1}^N \pi_n$ avec $\bar{q} = [q_1, \dots, q_I]$ où I est le nombre de composantes du vecteur caractéristique. Pour $W : W^* = \gamma C^{-1} = (\det(W^{-1}))^{1/I} C^{-1}$ avec $W = [w_{rs}]$ où $r, s = 1, \dots, I$.

VI.2.5 Considérations pratiques

Nous avons montré l'optimalité des solutions dans les sections précédentes. Dans cette section, nous allons discuter de certains aspects rencontrés en pratique.

Pour calculer la solution optimale pour W_i dans (VI.17), nous avons besoin de calculer l'inverse de la matrice de covariance C_i . Il est clair que, si $N < K_i$, C_i n'est inversible, et nous ne pouvons avoir W_i . Dans MindReader, les auteurs proposent une solution pour résoudre ce problème en utilisant une matrice pseudo-inverse définie ci-dessous.

La décomposition de la valeur singulière (*ang.* singular value decomposition, SVD) de C_i est

$C_i = A \Lambda B^T$, où Λ une matrice diagonale : $diag(\lambda_1, \dots, \lambda_j, \dots, \lambda_{K_i})$. Ces λ 's sont positifs ou nuls. Supposons qu'il y ait L λ 's non nuls, la pseudo-inverse de C_i est définie comme

$$C_i^+ = A \Lambda^+ B^T$$

$$\Lambda^+ = diag\left(\frac{1}{\lambda_1}, \dots, \frac{1}{\lambda_L}, 0, \dots, 0\right) \quad (\text{VI.25})$$

où, $' + '$ désigne la pseudo-inverse d'une matrice. L'approximation de solution W_i^* est donc

$$W_i^* = \left(\prod_{l=1}^L \lambda_l \right)^{\frac{1}{L}} C_i^+ \quad (\text{VI.26})$$

Toutefois, Rui et Huang [42] remarquent que cette solution conduit à de très faibles performances. Plus particulièrement, quand N est très petit par rapport à K_i . Ils estiment qu'il est préférable de n'utiliser qu'une matrice de pondération diagonale W_i correctement estimée, plutôt que de compter sur une matrice pleine mal estimée. Par conséquent, lorsque $N < K_i$ la matrice W_i est contrainte à être diagonale et dont les éléments sont l'inverse de l'écart type, i.e. $w_{i_{rs}} = 1/\sigma_{i_s}$ si $r = s$ et $w_{i_{rs}} = 0$, ailleurs. Inversement, lorsque $N > K_i$, une matrice pleine est considérée. Cette approche est beaucoup plus robuste du moment où elle a besoin seulement de deux exemples d'apprentissage pour estimer les paramètres. Kherfi et al. [45] proposent de remplacer l'écart type dans l'approche de Rui par les éléments de la diagonale de la matrice C_i donnée dans § VI.2.2, i.e. $W_i = \text{diag}(1/C_{i_{11}}, \dots, 1/C_{i_{ss}}, \dots, 1/C_{i_{K_i K_i}})$ où $C_{i_{ss}}$ peut être obtenu en posant $r = s$ dans (VI.16). C'est cette approche qu'on a appliquée dans cette thèse dans le cas où $N < K_i$.

VI.3 Méthodologie expérimentale

Notre tâche, dans cette partie du travail, est d'appliquer un SRIBC utilisant le retour de pertinence à une base d'images des défauts de soudure. Notre objectif est d'appliquer l'approche proposée pour répondre à la préoccupation suivante: étant donné un défaut ou un ensemble de défauts appartenant à une certaine classe, rechercher, dans la base de données entière, tous les défauts faisant partie de cette classe.

L'affectation de la ROI à telle ou telle classe de défauts est réalisée par un expert radiographe. Donc, tous les éléments de la base sont classés *a priori* pour constituer une base de référence, indispensable à l'évaluation du système de recherche. L'indexation de cette base est basée sur deux descripteurs de formes, le premier est le GFD et le second contient 8 mesures géométriques de formes noté GEO qui ont fait l'objet d'étude dans le chapitre précédent. L'étape de l'indexation est très importante car les résultats de la recherche en dépendent.

Pour valider le modèle de retour de pertinence dans le contexte de notre application, nous avons implémenté un système de recherche dans lequel une requête est formulée par l'utilisateur traduite par une image d'un défaut de soudure que l'on désire rechercher. Le système renvoie des images de défauts qui sont plus ou au moins satisfaisantes pour l'utilisateur. Ces premiers résultats ne font pas intervenir le retour de pertinence. Cette étape est appelée *Rf0*. Pour ajouter une image à la requête, ce dernier doit la choisir parmi les images renvoyées. En outre, l'utilisateur doit assigner un degré de pertinence à chaque image ajoutée. Les degrés de pertinence possibles sont :

- Très similaire : correspond à une valeur de pertinence de 2 pour une image positive.
- Similaire : correspond à une valeur de pertinence de 1 pour une image positive.
- N'importe pas ou différent : l'image ne participera pas dans la requête.

Une fois la formulation de la requête est terminée, l'utilisateur peut lancer l'opération de recherche (récupération). Le système calcule les paramètres optimaux qui minimisent l'équation de dispersion globale (VI.3) pour MindReader et (VI.6) pour le modèle de Rui et effectue la comparaison. Ainsi, les images de la base de données sont rangées par ordre croissant de leur distance à la requête. Cette distance pour MindReader (MR) est donnée par :

$${}^{MR}D_m = (\vec{x}_m - \vec{q}^*)^T W^* (\vec{x}_m - \vec{q}^*) \quad (\text{VI.25})$$

et pour le modèle de Rui, elle est donnée par

$${}^{Rui}D_m = \sum_{i=1}^I u_i^* (\vec{x}_{mi} - \vec{q}_i^*)^T W_i^* (\vec{x}_{mi} - \vec{q}_i^*) \quad (\text{VI.26})$$

$m = 1, \dots, M$ où M est le nombre des images dans la base de données.

Nous retournons les images des plus hauts rangs à l'utilisateur qui peut demander de voir plus d'images afin de formuler une nouvelle requête, etc. (voir Fig. VI.4).

VI.4 Un nouveau descripteur et évaluation du système de recherche

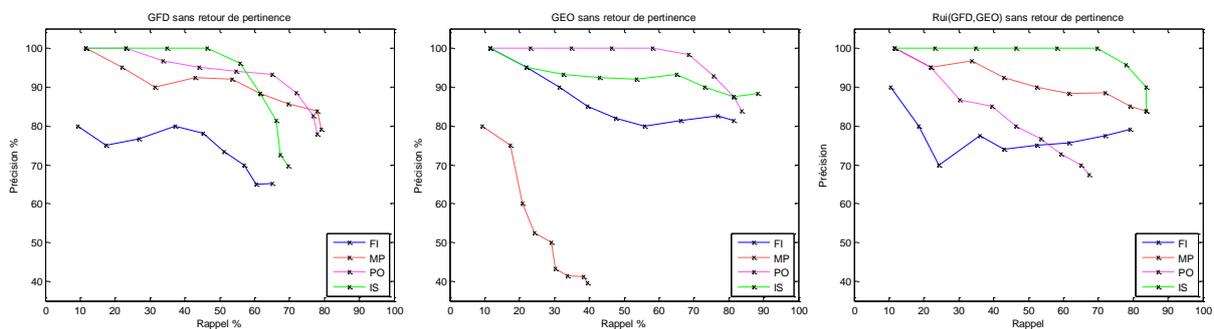
Les mesures de performance d'un système de recherche les plus utilisées sont la mesure du Rappel et de la Précision. Le rappel correspond « à la capacité du système à retourner un nombre d'objets pertinents le plus élevé possible » tandis que la précision indique « la capacité du système à retourner le moins possible d'objets non pertinents ». La précision (P) et le rappel (R) sont donnés par les formules suivantes :

$$P = \frac{|Pt \cap Rt|}{|Rt|} \quad (\text{VI.24})$$

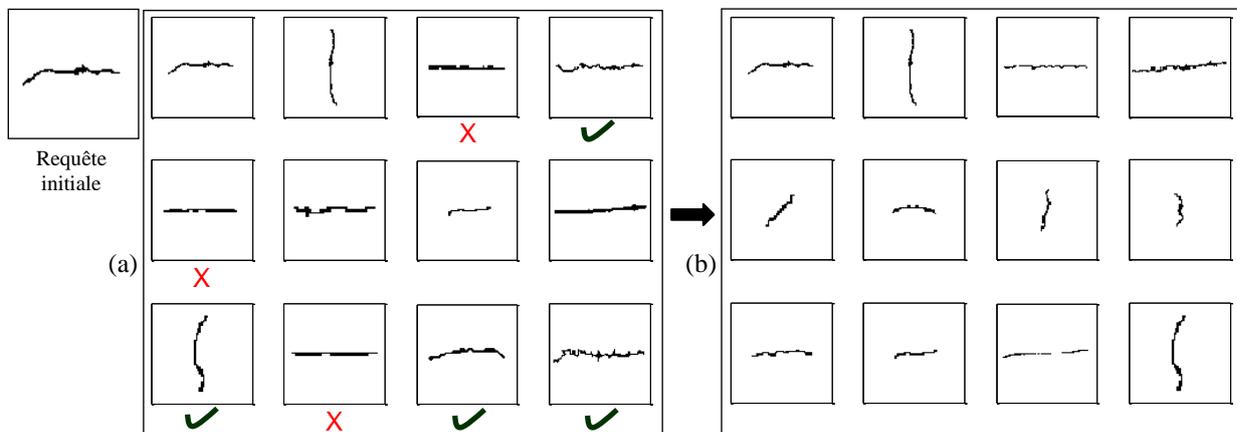
$$R = \frac{|Pt \cap Rt|}{|Pt|} \quad (\text{IV.25})$$

où $Pt \cap Rt$ désigne les objets pertinents retournés, Pt correspond à la totalité des objets pertinents et Rt désigne les objets retournés. $|\cdot|$ désigne la cardinalité. La précision est calculée à certains points du rappel (entre 0 et 100%). Ce qui donne la courbe des variations de la précision en fonction de celles du rappel.

Nous présentons dans Fig. VI.3, les performances des systèmes de recherche utilisant l'approche MindReader et le modèle de Rui sur la base des défauts indexée par les descripteurs GEO et GFD. Les résultats sont donnés pour chacun des types de défauts à savoir : FI, MP, PO et IS. Il apparaît à travers ces résultats que les descripteurs GFD et GEO utilisés séparément par MinReader ne sont pas performant quand à la récupération de FI et MP, respectivement. Le modèle de Rui qui utilise les deux descripteurs dans un schéma hiérarchisé augmente les performances de la recherche mais, celles-ci restent néanmoins en deçà des objectifs fixés dans cette thèse. Cependant, le retour de pertinence peut améliorer les résultats comme l'illustre Fig. VI.4, mais pas assez pour compenser l'insuffisance du caractère discriminant du descripteur, où, il est noté, dans le cas de cette figure, la difficulté du descripteur GFD à discriminer entre la fissure et le manque de pénétration pour l'étape $Rf0$.



VI.3. Courbe précision/rappel pour MindReader et le modèle de Rui utilisant GFD et GEO sans retour de pertinence



✓ Exemple retourné participant dans la nouvelle requête X Exemple non pertinent retourné

Fig. VI.4 (a) Etape $Rf0$ des résultats de recherche pour MinReader utilisant GFD. L'utilisateur choisit les exemples ajoutés à la requête initiale pour affiner la recherche dans $Rf1$ (b).

Pour pallier à ce problème, nous proposons un autre descripteur issu de la fusion des GEO et GFD selon la stratégie que nous exposons dans la suite. On sait que la fissure est caractérisée par une faible compacité (C) et une faible rectangularité (R), tandis que le manque de pénétration est caractérisé par une compacité faible mais une rectangularité grande. L'inclusion solide quant à elle, est caractérisée par une compacité moyenne et une rectangularité assez faible (voir Fig. VI.5). C'est pourquoi en substituant GFD par N_c éléments de la base (N_c est la cardinalité de chacune des classes, dans notre cas $N_c = 86$) ayant la plus faible somme pondérée : $S = 2 \times C + R$, par les GEO, les défauts de la 1^{ère} classe, i.e. les fissures auront la plus grande chance d'être représentés par GEO et ce, sans aucune connaissance *a priori* sur l'appartenance des images à telle ou telle classe. Ceci peut être confirmé par les graphes de Fig. VI.6 et les valeurs de la métrique de similarité utilisant la distance de Manhattan données dans Tableau VI.1. En effet, la plupart des fissures sont représentées par GEO dans le nouveau descripteur $f(\text{GFD}, \text{GEO})$ issu de la fusion des GFD et GEO et dont les proportions de représentation dans la totalité de la base sont respectivement $\frac{3}{4}$ et $\frac{1}{4}$; tandis que les autres défauts restent en majorité représentés par GFD.

Il est à noter qu'en raison d'exigence de l'opération de fusion, GEO a été interpolé pour passer de 8 composantes à 54 (le nombre de composantes des GFD). Le facteur de pondération 2 est utilisé pour donner plus d'importance à la compacité dans la discrimination de la 1^{ère} classe. Effectivement, les résultats donnés dans Figs. VI.7, VI.8 et VI.9, confirment l'efficacité du descripteur hybride proposé $f(\text{GFD}, \text{GEO})$, où les taux de récupération du système de recherche, sans et avec retour de pertinence, ont sensiblement augmenté par rapport aux autres variantes de GFD et GEO. En effet, le descripteur proposé surpasse même le descripteur GFD+GEO issu de la concaténation de GFD et GEO avec un modèle plat, le modèle hiérarchique de Rui car le problème réside dans la capacité de discrimination des GFD et GEO entre certaines classes (FI et MP) et leur combinaison simple ou hiérarchisé ne résout pas le problème, contrairement au descripteur fusionné $f(\text{GEO}, \text{GFD})$.

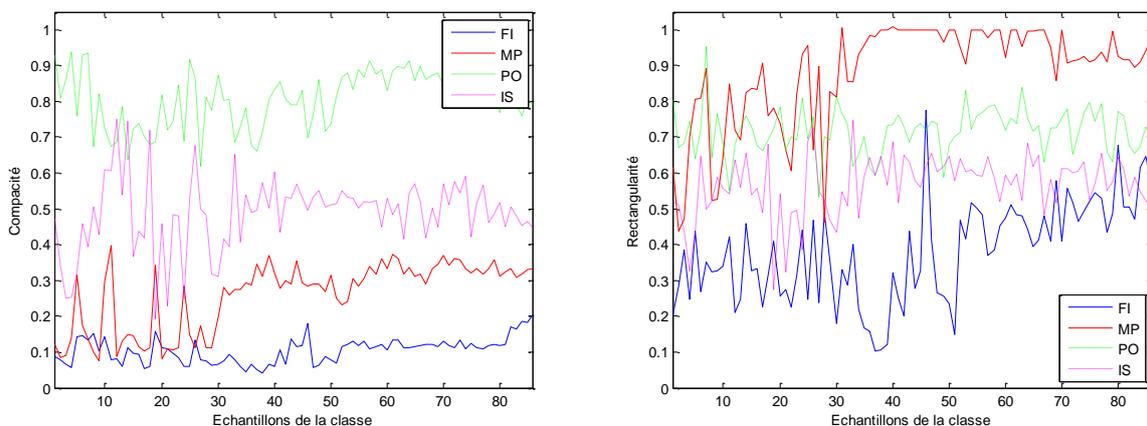


Fig. VI.5 Représentation de la compacité et de la rectangularité pour chacune des classes de défauts de la base

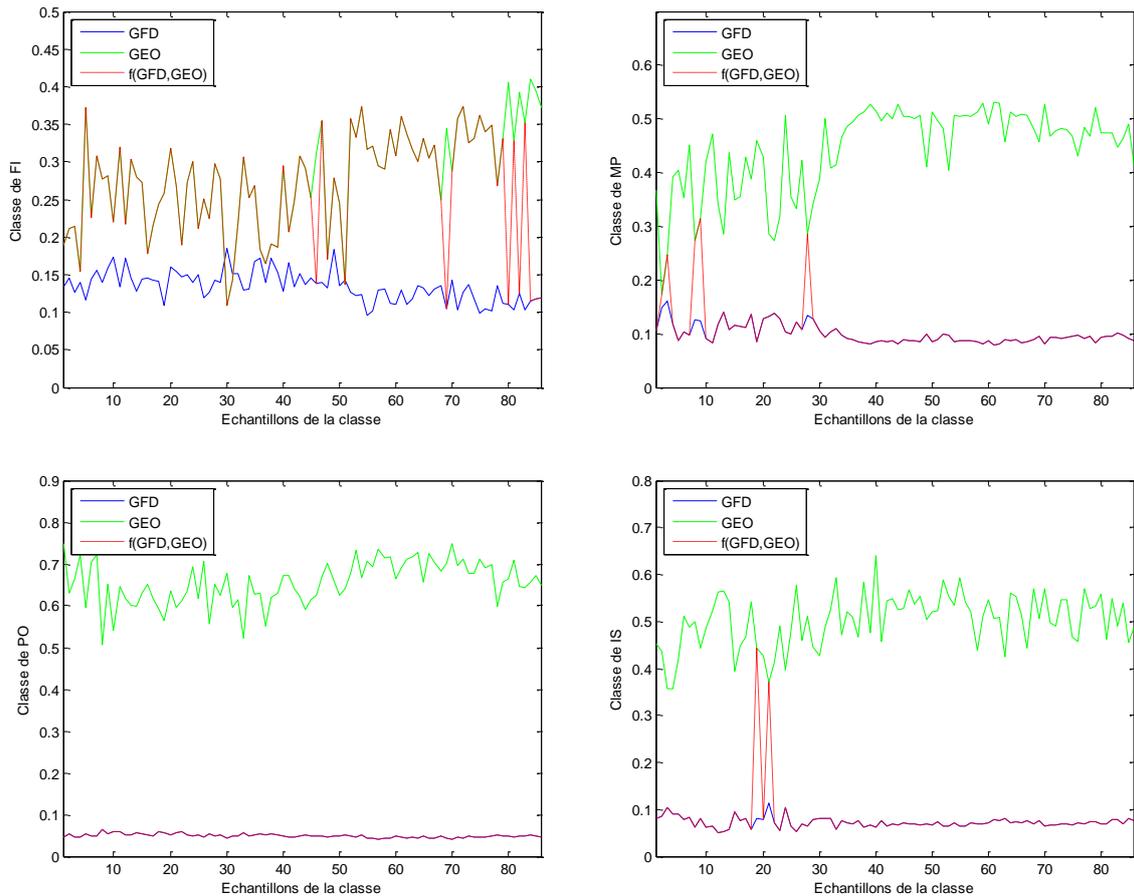


Fig. VI.6 Représentation la moyenne de chacun des descripteurs GFD, GEO, $f(GFD,GEO)$ pour chacune des classes des défauts de soudure.

Tableau V.1 Distance de Manhattan de GFD / $f(GFD,GEO)$ et GEO / $f(GFD,GEO)$ pour chaque classe de défauts de la base

	<i>FI</i>	<i>MP</i>	<i>PO</i>	<i>IS</i>
GFD / $f(GFD,GEO)$	0.1288	0.0070	0	0.0072
GEO / $f(GFD,GEO)$	0.0210	0.3370	0.6059	0.4225

Pour mieux voir l'influence du descripteur proposé, nous pouvons représenter les résultats précédents dans le cadre d'un calcul du taux de reconnaissance pour un tel descripteur. Si on met le nombre d'images retournées égal au nombre d'images de la classe et si chacune des images de la classe est prise comme requête, alors la moyenne de la précision définie plus haut, seront traduite par un taux de reconnaissance pour la classe. Le taux de reconnaissance global pour le descripteur est aussi déduit en prenant la moyenne des taux sur toutes les classes de la base. Tout en restant aussi performant que GFD, GEO, GFD+GEO $R_{ui}(GFD,GEO)$ pour la reconnaissance des classes PO et IS, $f(GFD,GEO)$ les surpasse quant à l'identification des classes FI et MP comme il est montré par les taux de reconnaissance dans Fig. VI.10.

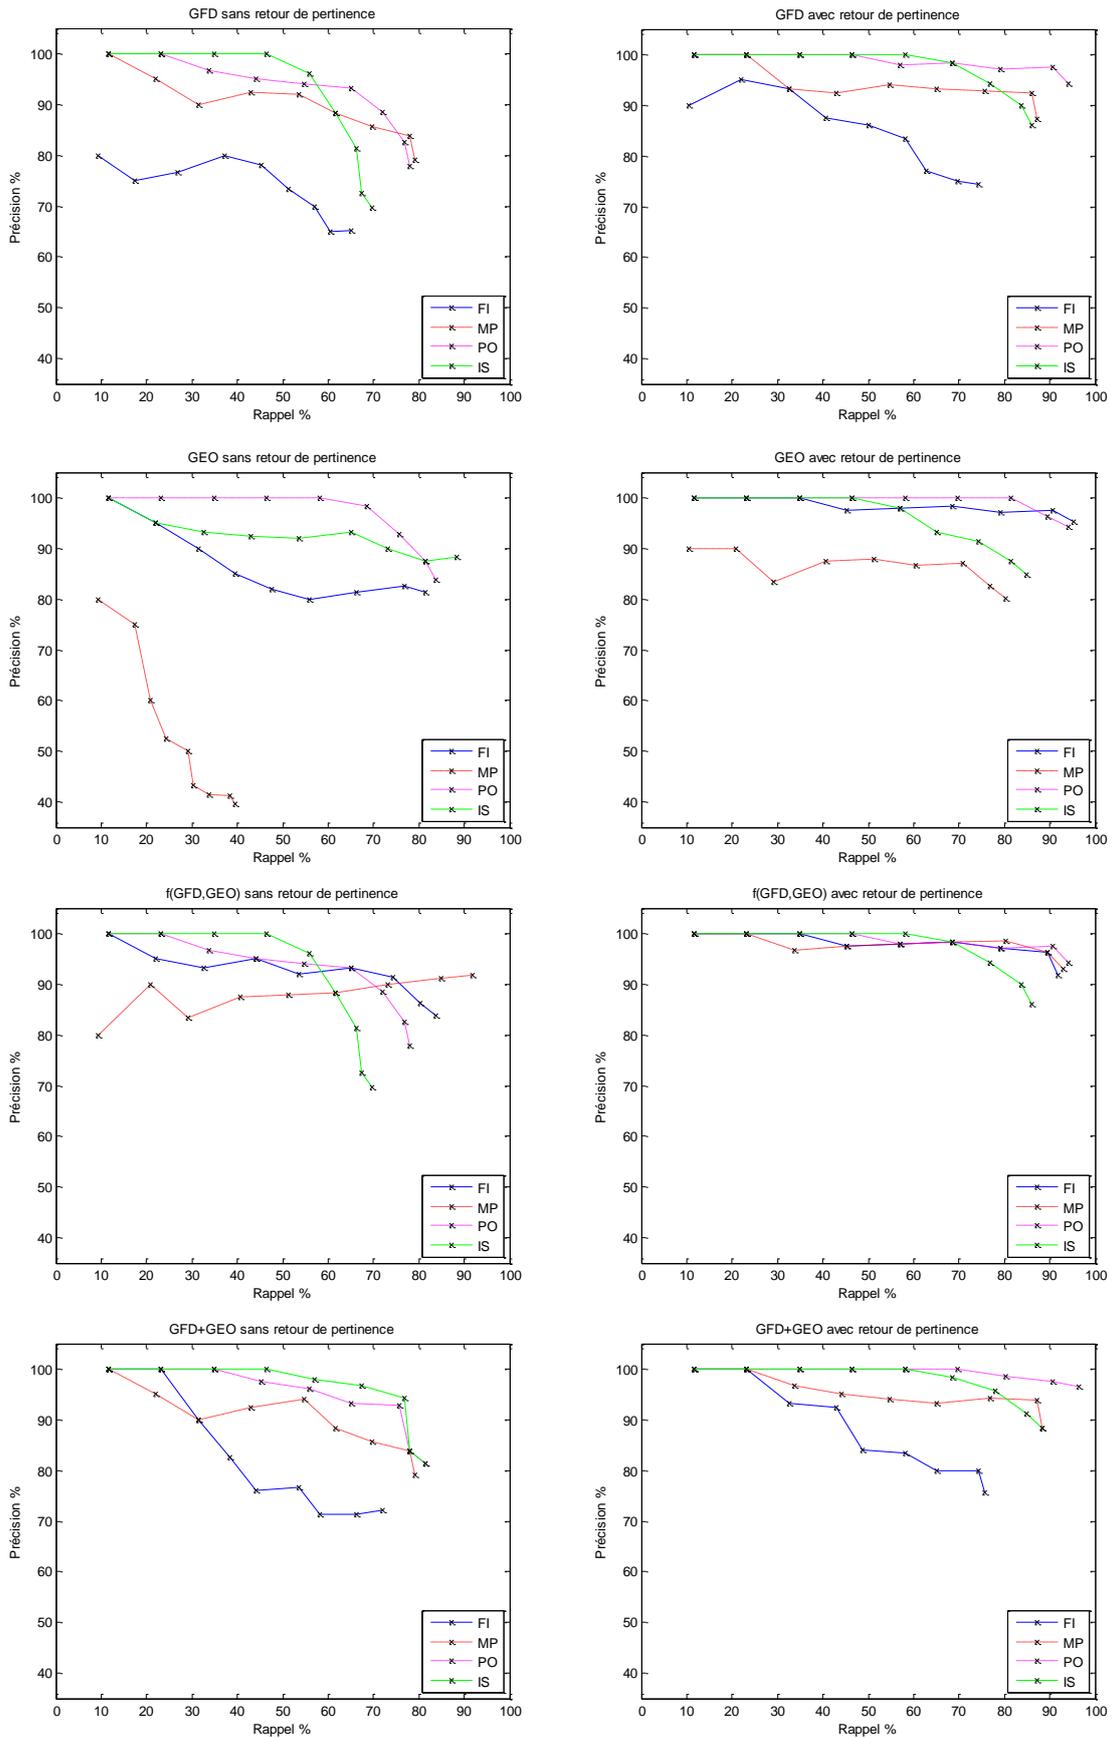


Fig. VI.7 Courbe rappel-précision : MindReader sans et avec retour de pertinence

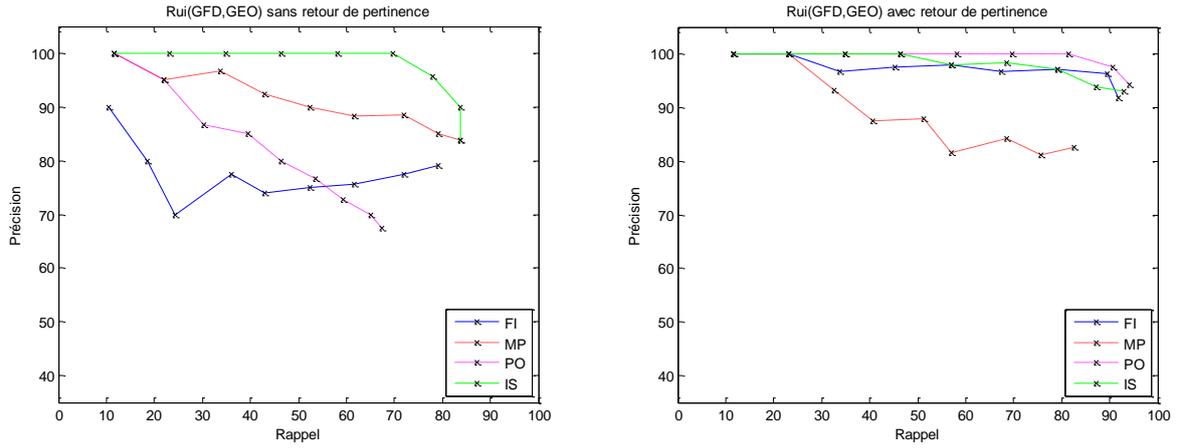


Fig. VI.8 Courbe rappel-précision : Modèle de Rui sans et avec retour de pertinence

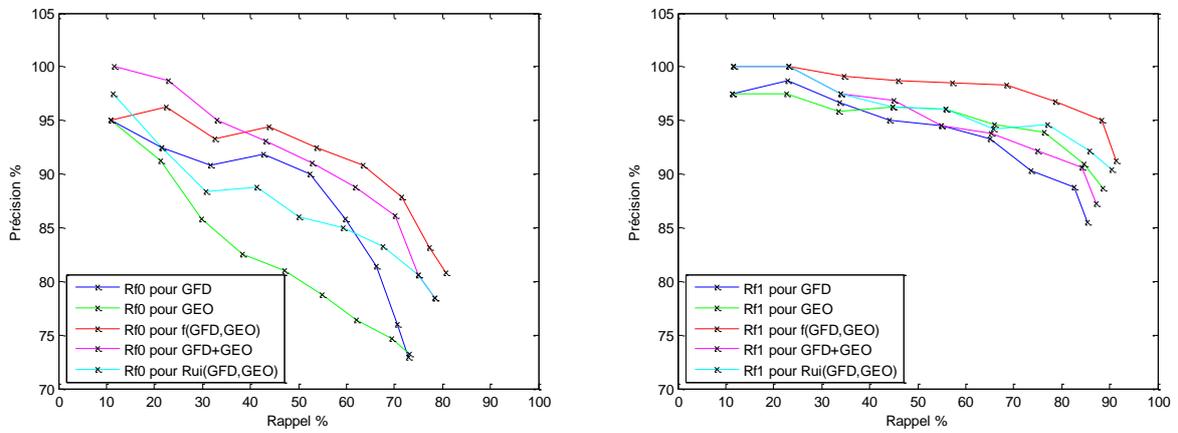


Fig. VI.9 Courbes rappel-précision : Résultats de MindReader utilisant GFD, GEO, f(GFD,GEO), GFD+GEO, Modèle de Rui utilisant GFD et GEO moyennés sur les 4 classes de défauts sans et avec retour de pertinence

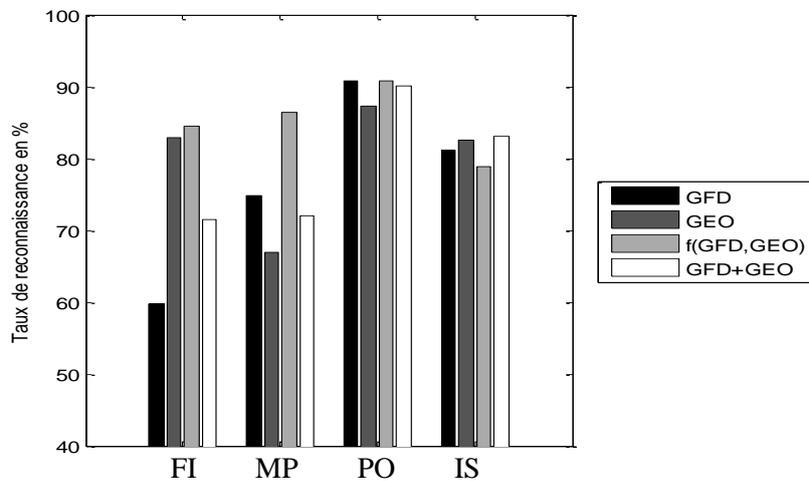


Fig. VI.10 Taux de reconnaissance pour chacun des types de défauts de la base.

Remarque : Dans ce travail, puisque le nombre des exemples d'apprentissage pris lors de la formulation de la requête est toujours inférieur à la dimensionnalité des descripteurs testés : 54 pour GFD, 8 pour GEO, 62 pour GFD+GEO, 54 pour $f(\text{GFD}, \text{GEO})$, la matrice W_i dans (VI.3) et (VI.6) est prise diagonale (selon l'approche de Kherfi et al. [45]) au lieu d'être prise pleine et ce, dans le but d'éviter le problème de l'inversion de la matrice de covariance requise dans le calcul de la matrice de poids optimaux comme il a été expliqué dans §VI.2.5.

VI.5 Conclusion

Nous avons montré dans ce chapitre la faisabilité de l'approche de la recherche d'image par le contenu dans le diagnostic des défauts dans les images radiographiques des joints soudés. L'avantage de l'approche de recherche par rapport à celle de la classification est qu'il n'est pas nécessaire de diviser la totalité des images de la base de données en classes ou catégories parce que seulement un sous-ensemble de cette base est recherché. Toutefois, la catégorisation des éléments de la base en classes est seulement nécessaire pour une évaluation préliminaire du système de recherche. Cette approche est particulièrement importante dans le cas des grandes bases de données. En effet, dans le contrôle par radiographie, nous sommes parfois intéressés par l'occurrence d'un certain type de défauts qui peut être dangereux pour le joint soudé considéré et par conséquent dangereux pour le composant industriel en question. Par exemple, toutes les normes du contrôle non destructif sont sévères au sujet des fissures; les soudures présentant de tels défauts sont systématiquement rejetées. Ainsi, un système de recherche d'image utilisant le retour de pertinence peut être vivement recommandé et ce, pour retrouver le type de défaut exigé sans se préoccuper d'autres types de défauts.

Deux méthodes de recherche-par-l'exemple basées optimisation ont été utilisées : MindReader et modèle de Rui. Les mesures de similarité utilisent deux types de descripteurs de formes GFD et GEO. Un nouveau descripteur basé sur la fusion de ces derniers a été proposé. Les expérimentations conduites sur la base de défauts attestent la supériorité de ce descripteur par rapport aux GFD et GEO, concaténés ou utilisés séparément, dans les modèles de MindReader et Rui. Il faut souligner que les résultats peuvent être affectés par le jugement de l'utilisateur dans le choix des requêtes. D'autant plus qu'il ne peut pas accéder à tous les exemples de la base pour formuler ses requêtes. Ce qui explique que mis à part le pouvoir discriminant du descripteur dans l'amélioration des résultats dans le retour de pertinence, il y a aussi l'aspect subjectif lié au choix des requêtes par l'utilisateur.

Conclusion générale et perspectives

Parmi les différentes techniques de traitement d'images en général et de segmentation en particulier, les méthodes statistiques ont été minutieusement étudiées et ont mené à des techniques innovatrices et puissantes. L'avantage principal de ces méthodes se situe dans leurs capacités à tenir compte d'une manière efficace de la nature des différents fluctuations et bruits présents dans l'image. En outre, elles permettent souvent de définir une méthodologie rigoureuse pour résoudre un problème donné de traitement d'image. Vu les spécificités des images radiographiques des défauts de soudure notamment le bruit élevé et le mauvais contraste, ces techniques sont les plus recommandées. Ainsi, dans la première partie de travail, nous avons développé et implémenté des méthodes de segmentation d'image utilisant des outils statistiques telles que : estimation par maximum *a posteriori*, l'histogramme des niveaux de gris, l'entropie, la matrice de cooccurrence, l'algorithme EM, le modèle de mélange des lois de probabilités, etc.

La première méthode est basée sur l'approche probabiliste des modèles déformables en utilisant un contour actif basé région. Le contour et les paramètres des régions sont obtenus grâce à la méthode de la théorie de l'estimation statistique du maximum *a posteriori* et de son cas particulier, le maximum de vraisemblance. Il se peut qu'au cours de sa convergence, le contour reste piégé dans un minimum local car la paramétrisation de la B-spline avec un nombre fixé de points de contrôle est incapable de s'adapter aux formes assez complexes ; ce que peut se traduire par une mauvaise segmentation. Alors, pour remédier à cette situation, nous avons proposé une modification originale de l'algorithme précédent. Le nombre de points de contrôle est donc pris adaptatif par une règle de division/fusion selon un critère lié à la distance entre deux points de contrôle successifs. Le déplacement du point de contrôle se fait selon la normale en ce point. Les résultats de cet algorithme sur des images radiographiques de défauts de soudures, caractérisées par un mauvais contraste et un fond texturé et à luminance variable sont très prometteurs dans la mesure où les contours estimés des défauts s'apparient bien à ceux esquissés manuellement par des interpréteurs en radiographie.

La deuxième méthode de segmentation utilisée consiste dans le seuillage. En effet, nous avons étudié expérimentalement l'efficacité de quelques méthodes basées sur les histogrammes 1-D et 2-D et les propriétés statistiques du voisinage du pixel à travers des images radiographiques de soudures. A la lumière des résultats de binarisation et des mesures des critères de performance, parmi les méthodes de seuillage basée sur l'histogramme 1-D, la méthode basée sur l'entropie semble être la plus adéquate, particulièrement pour les images bien contrastées. La méthode basée sur l'entropie relative est légèrement plus efficace que les autres méthodes dans l'approche basée sur l'histogramme 2-D. Cependant, pour les images mal contrastées où, la région du défaut est souvent noyée dans celle du fond, les méthodes localement adaptatives, particulièrement la méthode de Sauvola, s'avèrent être les plus adéquates.

Pour la segmentation d'images par estimation des paramètres statistiques d'un modèle de mélange, notre contribution consiste en l'utilisation de la distribution gaussienne généralisée en vue de la segmentation d'images radiographiques. Il apparaît à travers les résultats donnés par l'indice d'uniformité et le calcul d'erreurs, que la flexibilité du modèle de mélange basé sur la

gaussienne généralisée favorise une restitution plus fiable, par rapport au modèle gaussien, de l'emplacement des différents modes réellement contenus dans l'image. Ces derniers correspondent aux différentes partitions de l'image du film radiographique : le défaut, le cordon et le métal de base. Ce qui est traduit par de meilleurs résultats de segmentation pour le premier modèle (GGMM).

Dans le contrôle par radiographie, nous sommes parfois intéressés par l'occurrence d'un certain type de défauts sans pour autant être concerné par les autres types. A cet effet, un système de recherche d'images par le contenu peut répondre à cette exigence et ce que nous avons appliqué d'une manière originale dans ce travail. Dans un tel système, il n'est pas nécessaire de diviser la totalité des images de la base en classes ou catégories comme c'est le cas de la classification, parce que seulement un sous-ensemble de cette base est recherché. Un tel ou tel type de défaut peut être recherché pour diverse raisons telles que : évaluation particulière du procédé soudage, degré de nocivité pour le composant industriel en question, etc. En outre, un système de recherche d'images basée sur le contenu avec retour de pertinence peut donner une approche plus réaliste pour l'identification des défauts de soudures que celle donnée par la classification car l'intervention de l'expert radiographe est très importante dans l'interprétation. Chose que le système de recherche lui permet car il peut intervenir à travers le retour de pertinence.

En outre, nous avons proposé d'une manière originale, une stratégie d'hybridation ou de fusion du descripteur des mesures géométriques de forme (GEO) et du descripteur de Fourier générique (GFD). Les résultats de recherche dudit descripteur surpassent d'une manière significative ceux du GEO et GFD, concaténés ou utilisés séparément.

Une première perspective qui peut découler directement du travail réalisé est l'utilisation de l'approche des modèles déformables proposée pour la segmentation de toutes les images des radiogrammes de la base. Ainsi, l'indexation de cette dernière sera faite sur la base des images issues de ladite segmentation. Le premier avantage de l'utilisation du contour actif tel proposé et qu'on peut se passer des étapes de prétraitement et post-traitement généralement indispensables pour le seuillage. En effet, comme il a été mentionné, ce modèle de contour actif s'adapte bien aux images à fort bruit et à faible contraste. Le post-traitement n'est plus nécessaire car le contour actif est déjà fermé et la connexité n'est plus à vérifier lorsque la segmentation est terminée. L'autre avantage est que l'algorithme amélioré (Algo 2) semble donner des résultats de segmentation plus précis par rapport à ceux donnés par les méthodes de seuillage développées. Le principal inconvénient réside dans le fait que le modèle déformable développé est plus gourmand en temps de calcul.

Le partitionnement de l'image radiographique en ses composantes principales (défaut, joint soudé, métal de base) par une méthode de segmentation multimodale efficace à l'instar de GGMM peut être exploité dans des travaux futurs du moment où, certains défauts de soudure ne peuvent apparaître que dans des endroits précis du joint soudé. Donc la position du défaut (non pris isolé) par rapport au joint soudé peut nous renseigner sur les types de défauts dont il doit appartenir.

Références bibliographiques

- [1] J. H. Rogerson, "Defects in welds – Their prevention and their significance", Applied science publishers, 1983.
- [2] R.C. Master, "Non destructive Testing handbook", ASNT 1959.
- [3] Ch. Schwartz, "Automatic Evaluation of Welded Joints Using Image Processing on Radiographs", American Institute of Physics 657, pp. 689-694, 2003.
- [4] A.A. de Carvalho et al., "Evaluation of the relevant features of welding defects in radiographic inspection", Materials Research 6(3), pp. 427-432, 2003.
- [5] Y. J. Zhang, "Advances in image and video segmentation", IRM Press, 2006.
- [6] S.W. Lawson, G.A. Parker, "Intelligent Segmentation of Industrial Radiographic Images Using Neural Networks", in Proc. of SPIE Machine Vision Applications and Systems Integration III, pp. 245–255, 1994.
- [7] T.W. Liao, J. Ni, "An automated radiographic NDT system for weld inspection: Part I - Weld extraction", NDT & E International 29(3), pp. 157-162, 1996.
- [8] Y. Kabir, "Segmentation d'images de films de radiographie dédiée au contrôle non destructif ", Mémoire de magister, Université de Blida, 1999.
- [9] **N. Nacereddine**, R. Draï, A. Benchaala, "Weld defect Extraction and Classification in radiographic testing based Artificial Neural Networks", WCNDT, Roma, 2000.
- [10] G. Li, G. Wang, Z. Jiguang, "A Genetic Algorithm on Welding Seam Image Segmentation", in IEEE Proc. of the 5th World Congress on Intelligent Control and Automation, China, 2004.
- [11] X. Wang, B.S. Wong, "Segmentation of radiographic images using fuzzy c-means algorithm", Insight 47, pp. 631-633, Oct 2005.
- [12] **N. Nacereddine**, L. Hamami, M. Tridi, N. Oucief, "Histogram-based and locally adaptive thresholding techniques for weld defect extraction in digital radiography", Defectoscopy'05, République tchèque, Nov. 2005.
- [13] **N. Nacereddine**, L. Hamami, D. Ziou, M. Tridi, "Probabilistic Deformable Model for Weld Defect Contour Estimation in Radiography", Machine Graphics & Vision 15(3/4), pp. 547–556, 2006.
- [14] **N. Nacereddine**, L. Hamami, D. Ziou, "Thresholding Techniques and their Performance Evaluation for Weld Defect Detection in Radiographic Testing", Machine Graphics & Vision 15(3/4), pp. 557–566, 2006.
- [15] F. Mekhalfa, **N. Nacereddine**, A.B. Goumeidane, "Unsupervised Algorithm for Radiographic image Segmentation based on the Gaussian Mixture Model", IEEE Conference on "Computer as a tool" EUROCON'07, Varsovie, pp. 289-293, 2007.
- [16] A.B. Goumeidane, M. Khamadja, **N. Nacereddine**, F. Mekhalfa, "Parametric Active Contour for Weld Defect Boundary Extraction in Radiographic testing", in Proc. of SPIE 6356, 8th Inter. Conf. on Quality Control by Artificial Vision, Le Creusot, France, 23-25 Mai 2007.
- [17] **N. Nacereddine**, L. Hamami, D. Ziou, "Image Thresholding for Weld Defect Extraction in Industrial Radiographic Testing", International Journal of Signal Processing 3(4), pp. 257-265, 2007.
- [18] Q.M. Shen, J.M. Gao, C. Li, "Adaptive segmentation of weld defects based on flooding", Insight 51(10), 2009.
- [19] **N. Nacereddine**, S. Tabbone, D. Ziou, L. Hamami, "L'algorithme EM et le Modèle de Mélanges de Gaussiennes Généralisées pour la Segmentation d'images. Application au contrôle des joints soudés par radiographie", TAIMA'09, Hammamet, Tunisie, pp. 217–222, Mai 2009.

- [20] A.B. Goumeïdane, M. Khamadja, **N. Nacereddine**, “Bayesian Pressure Snake for Weld Defect Detection”, ACIVS 2009, LNCS 5807, Springer, pp. 309–319, 2009.
- [21] **N. Nacereddine**, L. Hamami, D. Ziou, A.B. Goumeïdane, “Adaptive B-spline model based Probabilistic Active Contour for Weld Defect Detection in Radiographic Imaging”, IP&C’10, Advances in Intelligent Soft Computing 84, Springer, pp. 289-297, 2010.
- [22] A.B. Goumeïdane, M. Khamadja, **N. Nacereddine**, “Adaptive and statistical polygonal curves for multiple weld defects detection in radiographic inspection”, International Conference on Digital Information and Communication Technology and its Applications (DICTAP’10), Dijon, 21-23 Jun. 2010.
- [23] **N. Nacereddine**, “Mise au point d’une méthode de détection et classification automatisée des défauts de soudure en radiographie industrielle”, Mémoire de magister, Université de Boumerdes, 2004.
- [24] **N. Nacereddine**, M. Zelmat, S. Belaïfa, M. Tridi, “Weld defect detection in industrial radiography based digital image processing”, SETIT’05, Tunisie, 2005.
- [25] H. Kim, J. Kim, “Region-based shape descriptor invariant to rotation, scale and translation”, Signal Process. Image Commun. 16, pp. 87-93, 2000.
- [26] **N. Nacereddine**, M. Tridi, “Computer-aided shape analysis and classification of weld defects in industrial radiography based invariant attributes and neural networks”, IEEE Fourth Intern. Symposium on Image and Signal Processing and Analysis, Zagreb, pp. 88-93, 2005.
- [27] D. Zhang, G. Lu, “Shape-based image retrieval using generic Fourier descriptor”, Signal Processing, vol. 17, pp. 825-848, 2002.
- [28] C. Jacobsen, U. Zscherpel, C Nockemann, “Crack Detection in Digitized Radiographs with Neuronal Methods”, ECNDT, Copenhagen, pp 2717-2724, 1998.
- [29] K. Aoki, Y. Suga, “Application of artificial neural network to discrimination of defect type automatic radiographic testing of welds”, ISI International 39(10), pp. 1081-1087, 1999.
- [30] S.V. Barai, P. Agrawal, “Parallel Neuro Classifier for Weld Defect Classification”, Advances in Soft Computing (Springer) 34, pp. 37-54, 2006.
- [31] T.Y. Lim, M.M. Ratnam, M. Khalid, “Automatic classification of weld defects using simulated data and an MLP neural network”, Insight 49(3), pp. 154-159, 2007.
- [32] X. Wang,, B. S. Wong, C.S. Tan, “Recognition of Welding Defects in Radiographic Images by using Support Vector Machine Classifier”, Research Journal of Applied Sciences, Engineering and Technology 2(3), pp. 295-301, 2010.
- [33] V. Lashkia, “Defect detection in X-ray images using fuzzy reasoning”, Image and Vision Computing 19(5), pp. 261-269, 2001.
- [34] T.W. Liao, “Classification of welding flaw types with fuzzy expert systems”, Expert Systems with Applications 25, pp. 101-111, 2003.
- [35] R.R. da Silva, M.H.S. Siqueira, L.P. Calôba, J.M.A. Rebello, “Radiographics pattern recognition of welding defects using linear classifiers”, Insight 43(10), 2001.
- [36] H.I. Shafeek, E.S. Gadelmawala, A.A. Abbel-Shafy, “Automatic inspection of gas pipeline welding defects using an expert vision system”, NDT&E International 37(4), pp. 301-307, 2004.
- [37] **N. Nacereddine**, M. Tridi, N. Oucief, “Neural networks and EM algorithm for weld defect classification in industrial radiography through invariant shape analysis”, IEEE International Computer Systems & Information Technology Conference, Algiers, Jul. 2005.
- [38] **N. Nacereddine**, L. Hamami, D. Ziou, “Invariant Shape Features and Relevance Feedback for Weld Defect Image Retrieval”, IEEE International Conference on Human Machine Interaction, Timimoun, Mar. 2007.

- [39] Y. Ishikawa, R. Subramanya, C. Faloutsos, "MindReader: Querying databases through multiple examples", in 24th International Conference on Very Large Data Bases, New York, pp. 433-438, 1998.
- [40] E. di Sciascio, M. Mongiello, "Query by sketch and relevance feedback for Content-Based Image Retrieval over the Web", *Journal of Visual Languages and Computing* 10, pp. 565-584, 1999.
- [41] S. Krishnamachari, M. Abdel-Mottaleb, "Hierarchical clustering algorithm for fast image retrieval", in Proc. of SPIE Conference on Storage and Retrieval for Image and Video Databases, San Jose, CA, 1999.
- [42] Z.Y. Rui, T.S. Huang, "Optimizing learning in image retrieval", in IEEE Conference on Computer Vision and Pattern Recognition, Hilton Head, SC, 2000.
- [43] Z. Su, H. Zhang, S. Li, S. Ma, "Relevance Feedback in Content-Based Image Retrieval: Bayesian Framework, Feature Subspaces, and Progressive Learning", *IEEE Trans. Image Process.* 9(8), pp. 924-937, 2003.
- [44] L. Wang, K.L. Chan, "A Dynamic Sub-vector Weighting Scheme for Image Retrieval with Relevance Feedback", *Pattern Analysis and Applications* 6, pp. 212-223, 2003.
- [45] M.L. Kherfi, D. Ziou, A. Bernardi, "Combining Positive and Negative Examples in Relevance Feedback for Content-Based Image Retrieval", *Journal of Visual Communication and Image Representation* 14(4), pp. 428-457, 2003.
- [46] M. Crucianu, M. Ferecatu, N. Boujemaa, "Relevance Feedback for Image Retrieval: a Short Survey", in Report of the European Network of Excellence, 2004.
- [47] R. Missaoui, M. Sarifuddin, J. Vaillancourt, "Similarity measures for efficient content-based image retrieval", *IEE Proc. Vis. Imag. Sig. Proc.* 152(6), pp. 875-887, 2005.
- [48] M.L. Kherfi, D. Ziou, "Relevance Feedback for CBIR: A New Approach Based on Probabilistic Feature Weighting With Positive and Negative Examples", *IEEE Transactions on Image Processing* 15(4), pp. 1017-1030, 2006.
- [49] "Classification des défauts dans les soudures par fusion des métaux, avec commentaires explicatifs". Norme de "International Standard Organization", 6520-1982, 1982.
- [50] "Guide for the Non-destructive Inspection of Welds". ANSI, American Welding Society, B1, 10-86, USA, 1987.
- [51] W.J. Mc Gonnagle, "Essais non destructifs", Edition Eyrolles, 1967.
- [52] "Soudages et techniques connexes, Tome 3 : Contrôles et Essais", Recueil des Normes Françaises, Edition AFNOR, Paris, 1994.
- [53] R. Halmshaw, "Radiographie industrielle", Agfa-Gevaert N.V. 1988.
- [54] L. Cartz, "Non destructive testing: Radiography, Ultrasonics, Liquid penetrant, Magnetic particles, eddy current", Hardcover edition, 1995.
- [55] Y. Kato et al., "Système automatique d'identification des défauts de soudures", *Soudage et techniques connexes*, Sept. Oct. 1993.
- [56] R.C. Gonzalez, R.E. Woods, "Digital Image Processing". Addison-Wesley Publishing Company, 1993.
- [57] S. Castan, "Vision par ordinateur", *Techniques de l'ingénieur, Traité Informatique*, vol. H2, Fasc. H1980, Dec. 1985.
- [58] J. Portilla, P.E. Simoncelli, "Image Restoration using Gaussian Scale Mixtures in the Wavelet Domain", 9th IEEE Conference on Image Processing, Barcelona, Spain, Sept. 2003.
- [59] I. El Feghi, S. Huang, M.A. Sid-Ahmed, M. Ahmadi, "Contrast enhancement of radiograph image based on local heterogeneity measures", *Int. Conf. Image Processing*, 2004.
- [60] L. Shapiro, G. Stockman, "Computer Vision", New Jersey, Prentice-Hall, pp 279-325, 2001.

- [61] L. Soler, G. Malandrin, H. Delingette, "Segmentation automatique: Application aux angioscanners 3D", *Revue de Traitement de signal* 15(5), pp. 411–431, 1998.
- [62] J. Velut, "Segmentation par modèle déformable surfacique localement régularisé par spline lissante", Thèse de doctorat, Institut National des Sciences Appliquées de Lyon, 2007.
- [63] M. Kass, A. Witkin, D. Terzopoulos, "Snakes: Active contour models", *Int. J. Computing and Vision* 1(4), pp. 321–331, 1988.
- [64] M. Berger, "Les contours actifs : modélisations, comportement et convergence", Thèse de doctorat, Institut polytechnique de Lorraine, 1991.
- [65] C. Davatzikos, J. Prince, "An active contour model for mapping the cortex", *IEEE Trans. Medical Imaging* 14, pp. 65-80, 1995.
- [66] L.D. Cohen, "On active contour models and balloons", *Comput Vision Graphics Image Process: Image Understand.* 53, pp.211–218, 1991.
- [67] D.J. Williams, M. Shah, "A fast algorithm for active contours and curvature estimation", *Computer Vision, Graphics, and Image Processing: Image Understanding* 55(1), pp. 14–26, 1992.
- [68] I.C. Greg, J.-N. Hwang, "A neural network-based stochastic active contour model (nns-snake) for contour finding of distinct features", *IEEE Trans. Image Processing* 4, pp. 1407-1406, 1995.
- [69] B. Leroy, I. Herlin, L.D. Cohen, "Multi-resolution algorithms for active contour models", 12th Int. Conf. Analysis and Optimization of Systems, pp. 58-65, 1996.
- [70] C. Xu, J. Prince, "Snakes, shapes, and gradient vector flow", *IEEE Trans. Image Processing* 7(3), pp. 359-369, 1998.
- [71] C. Xu, J. Prince, "Generalized gradient vector flow: External forces for active contours", *Signal Processing* 71, pp. 131-139, 1998.
- [72] H. Tek, B.B. Kimia, "Volumetric segmentation of medical images by three dimensional bubbles", *Comp. Vis. Imag. Under.* 65, pp. 246–258, 1997.
- [73] C. Xu, Y. Anthony, J. Prince, "On the relationship between parametric and geometric active contours", in *Proc. of the 34th IEEE Asilomar conference on signals, systems, and computers*, pp. 483–489, 2000.
- [74] S. Osher, J. Sethian, "Fronts propagating with curvature dependent speed: algorithms based on the Hamilton-Jacobi formulation", *J. Comput. Phys.* 79, pp. 12–49, 1988.
- [75] G. Sapiro, "Geometric partial differential equations and image analysis", Cambridge University Press, 2001.
- [76] D. Chop, "Computing minimal surfaces via level set curvature-flow", *Journal of Computational Physics* 106, pp. 77–91, 1993.
- [77] D. Adalsteinsson, J.A. Sethian, "A fast level set method for propagating interfaces", *Journal of Computational Physics* 118(2), pp. 269–277, 1995.
- [78] J.A. Sethian, "A fast marching level set method for monotonically advancing fronts", *Proceedings of the National Academy of Science* 93(4), pp. 1591–1595, 1996.
- [79] R. Malladi, J. Sethian, B. Vemuri, "Shape modeling with front propagation: A level set approach", *IEEE Trans Pattern Anal Machine Intell* 17, pp. 158 –175, 1995.
- [80] V. Caselles, F. Catte, T. Coll, F. Dibos, "A geometric model for active contours in image processing", *Num. Math.* 66, pp. 1–31, 1993.
- [81] V. Caselles, R. Kimmel, G. Sapiro, "Geodesic active contours", *International conference on computer vision, Boston, USA*, pp. 694-699, 1995.
- [82] B.A. Dubrovin, A.T. Fomenko, S.P. Novikov, "Modern geometry – Methods and applications I. Springer-Verlag, New-York, 1984.

- [83] V. Caselles, R. Kimmel, G. Sapiro, "Geodesic active contours", *International Journal of Computer Vision* 22(1), pp. 61-79, 1997.
- [84] S. Kichenassamy, A. Kumar, P. Olver, A. Tannenbaum, A. Yezzi, "Gradient flows and geometric active contour models", dans *Proc. of IEEE Fifth International Conference on Computer Vision*, pp. 694-699, 1995.
- [85] L. Cohen, E. Bardinet, N. Ayache, "Surface reconstruction using active contour models", in *SPIE Conference on Geometric Methods in Computer Vision*, San Diego, CA, 1993.
- [86] R. Ronfard, "Region-based strategies for active contour models", *International Journal of Computer Vision* 13(2), pp. 229-251, 1994.
- [87] S. Zhu, A. Yuille, "Region competition: unifying snakes, region growing, and bayes/MDL for multiband image segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence* 18, pp. 884-900, 1996.
- [88] O. Germain, P. Réfrégier, "Optimal snake-based segmentation of a random luminance target on a spatially disjoint background", *Optics Letters* 21(22), pp. 1845-1848, 1996.
- [89] Yezzi, A. Tsai, A. Willsky, "A statistical approach to snakes for bimodal and trimodal imagery", in *International Conference on Image Processing*, Kobe, Japan, pp. 898-903, 1999.
- [90] C. Chesnaud, "Technique statistiques de segmentation par contour actif et mise en œuvre rapide", Thèse de doctorat, Ecole nationale supérieure de physique de Marseille, Fév. 2000.
- [91] J.M.B. Dias, "Adaptive bayesian contour estimation: A vector space representation approach", *LNCS 1654*, Springer, pp. 157-172, 1999.
- [92] M.A.T. Figueiredo, J.M.N. Leitao, A.K. Jain, "Unsupervised contour representation and estimation using b-splines and a minimum description length criterion", *IEEE Transactions on Image Processing* 9(6), pp. 1075-1087, 2000.
- [93] N. Paragios, R. Deriche, "Geodesic Active Regions and Level Set Methods for Supervised Texture Segmentation", *International Journal of Computer Vision* 46 (3), pp. 223-247, 2002.
- [94] T. Chan, L. Vese, "Active contours without edges", *IEEE Transactions on Image Processing* 10(2), pp. 266-277, 2001.
- [95] Mumford, J. Shah, "Optimal approximations by piecewise smooth functions and associated variational problems", *Communications on Pure and Applied Mathematics* 42, pp. 577-684, 1989.
- [96] S. Jehan-Besson, M. Barlaud, G. Aubert, "DREAM²S: Deformable regions driven by an Eulerian accurate minimization method for image and video segmentation", *International Journal of Computer Vision* 53(1), pp. 45-70, 2003.
- [97] F. Precioso, M. Barlaud, T. Blu, et M. Unser, "Robust real-time segmentation of images and videos using a smooth-spline snake-based algorithm", *IEEE Transactions on Image Processing* 14(7), pp. 910-924, 2005.
- [98] P. Martin, P. Réfrégier, F. Galland, F. Guéroult, "Nonparametric statistical snake based on the minimum stochastic complexity", *IEEE Transactions on Image Processing* 15(9), pp. 2762-2770, 2006.
- [99] Herbulot, "Mesures statistiques non-paramétriques, pour la segmentation d'images et de vidéos et minimisation par contours actifs", Thèse de doctorat, Université de Nice - Sophia Antipolis, 2007.
- [100] F. Precioso, "Contours actifs paramétriques pour la segmentation d'images et vidéos", Thèse de doctorat, Université de Nice - Sophia Antipolis, 2004.
- [101] C. Chesnaud, P. Refregier, V. Boulet, "Statistical region snake-based segmentation adapted to different physical noise models", *IEEE Transactions on PAMI* 21(11), pp. 1145-1156, 1999.

- [102] S. Jehan-Besson, "Modèles de contours actifs bases regions pour la segmentation d'images et de vidéos", Thèse de doctorat, Université de Nice, 2003.
- [103] A. Chakraborty, L. Staib, J. Duncan, "Deformable boundary finding in medical images by intergrading gradient and region information," *IEEE Trans. on Medical Imaging* 15, pp. 859-870, 1996.
- [104] C. Kervrann, F. Heitz, "A hierarchical statistical framework for the segmentation of deformable objects in image sequences", *Proc. IEEE Conf. Comp. Vis. Patt. Recog.*, Seattle, pp. 724-728, 1994.
- [105] X. Bresson, P. Vandergheynst, J.-P. Thiran, "Variational model for object segmentation using boundary information and shape prior driven by the Mumford-Shah functional", *International Journal of Computer Vision* 28(2), pp. 145-162, 2006.
- [106] M. Unser, "Splines: A perfect fit for signal and image processing", *IEEE Signal Processing Magazine* 16(6), pp. 22-38, Nov. 1999.
- [107] M. Jacob, T. Blu, M. Unser, "A unifying approach and interface for spline based snakes", *SPIE* 4322, San Diego CA, USA, pp. 340-347, Feb. 2001.
- [108] C. de Boor, "A Practical Guide to Splines", Springer-Verlag, 2000.
- [109] J. Mille, "Modèles déformables pour la segmentation et le suivi en imagerie 2D et 3D", Thèse de doctorat, Université de Tours, 2007.
- [110] I.J. Schoenberg, "Spline functions and the problem of graduation", *Proceedings of the American Mathematical Society*, 1964.
- [111] J. Montagnat, "Modèles Déformables pour la segmentation et la modélisation d'images médicales 3D et 4D", Thèse de doctorat, Université de Nice - Sophia Antipolis, 1999.
- [112] A.A. Amini, T.E. Weymouth, R.J. Rain, "Using dynamic programming for solving variational problems in vision", *IEEE Transactions on PAMI* 12(9), pp. 855-867, 1990.
- [113] M. Sakalli, K.M. Lam, H. Yan, "A faster converging snake algorithm to locate object boundaries", *IEEE Transactions on Image Processing* 15(5), pp. 1182-1191, 2006.
- [114] J. Mille, R. Boné, P. Makris, H. Cardot, "Greedy algorithm and physics-based method for active contours and surfaces: a comparative study", in *IEEE International Conference on Image Processing*, Atlanta, USA, pp. 1645-1648, 2006.
- [115] M. Figueiredo, J. Leitão, "Bayesian estimation of ventricular contours in angiographic images", *IEEE Trans. Med. Imag.* 11, pp. 416-429, Mar. 1992.
- [116] G. Storvik, "A Bayesian approach to dynamic contours through stochastic sampling and simulated annealing", *IEEE Trans. Pattern Anal. Machine Intell.*, 16(10), pp. 976-986, 1994.
- [117] J.M.B. Dias, J.M.N. Leitão, "Wall position and thickness estimation from sequences of echocardiographic images", *IEEE Trans. on Medical Imaging* 15(1), pp.25-38, 1996.
- [118] O. Germain, P. Réfrégier, "Edge detection and localisation in SAR images : a comparative study of global filtering and active contour approaches," in *EurOpto Conf. on Image and Signal Processing for remote Sensing*, Barcelona, pp. 111-121, 1998.
- [119] D.L. Snyder, T.L. Schluz, "High resolution imaging at low-light levels through weak turbulence", *Journal of the optical society of America A* 7 (7), pp. 1251-1265, 1990.
- [120] M. Sezgin, B. Sankur, "Survey over image thresholding techniques and quantitative performance evaluation", *Journal of Electronic imaging* 13(1), pp. 146-165, 2004.
- [121] S.U. Lee, S.Y. Chung, R.H. Park, "A Comparative Performance Study of Several Global Thresholding Techniques for Segmentation", *Computer Vision, Graphics, and Image Processing* 52, pp. 171-190, 1990.

- [122] Y.J. Zhang, "A survey on evaluation methods for image segmentation", *Pattern Recognition* 29(8), 1996.
- [123] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms", *IEEE Trans. on Systems, Man, and Cybern. SMC-9*, pp. 62-66, 1979.
- [124] J. Kittler, J. Illingworth, "Minimum Error Thresholding", *Pattern Recognition* 19(1), 1986.
- [125] Silviu Guiasu, Radu Theodorescu, "Incertitude et Information", Les presses de l'université Laval, Quebec, 1971.
- [126] J.N. Kapur, P.K. Sahoo, A.K.C. Wong, "A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram", *Computer Vision, Graphics, and Image Processing* 29, pp. 273-285, 1985.
- [127] W-H. Tsai, "Moment-Preserving Thresholding: A New Approach", *Computer Vision, Graphics, and Image Processing* 29, pp. 377-393, 1985.
- [128] N.R. Pal, S.K. Pal, "Entropy thresholding", *Signal Processing* 16, pp. 97-108, 1989.
- [129] S.S. Lee, S.J. Horng, H.R. Tsai, "Entropy Thresholding and Its Parallel Algorithm on the Reconfigurable Array of Processors with Wider Bus networks", *IEEE Trans. Image Processing* 8(9), pp.1229-1242, Sept. 1999.
- [130] C.I. Chang, K. Chen, J. Wang, M.L.G. Althouse, "A Relative entropy-based approach to image thresholding", *Pattern Recognition* 27(9), pp. 1275-1289, 1994.
- [131] F. Shafait, D. Keysers, T.M. Breuel, "Efficient implementation of local adaptive thresholding techniques using integral images", *Document Recognition and Retrieval XV, Proc. SPIE 6815*, San Jose, CA, 2008.
- [132] W. Niblack, "Introduction to digital image processing", Prentice Hall, 1986.
- [133] J. Sauvola, M. Pietikainen, "Adaptive document image binarization", *Pattern Recognition* 33, pp. 225-236, 2000.
- [134] W.A. Yasnoff, J.K. Mui, J.W. Bacus, "Error measures for scene segmentation", *Pattern Recognition* 9, pp. 217-231, 1977.
- [135] M.D. Levine, A.M. Nazif, "Dynamic measurement of computer generated image segmentations", *IEEE Trans. PAMI* 7, pp. 155-164, 1985.
- [136] P.K. Sahoo, S. Soltani, A.K.C. Wong, "A survey of thresholding techniques", *Computer Vision, Graphics, and Image Processing* 41, pp. 233-260, 1988.
- [137] J. Serra, "Image analysis and mathematical morphology", part II: theoretical advances, J. Serra (Ed.), Academic Press, London, 1988.
- [138] R.M. Haralick, S.R. Sternberg, X. Zhuang, "Image analysis using mathematical morphology", *IEEE Trans. Pattern Analysis and Machine Intelligence* 9(4), pp.532-550, 1987.
- [139] M.S. Allili, N. Bouguila, D. Ziou, "Finite Generalized Gaussian Mixture Modeling and Applications to Image and Video Foreground Segmentation", in *Proc. of Fourth Canadian Conference on Computer and Robot Vision*, Montreal, pp. 183-190, 2007.
- [140] Y. Bazi, L. Bruzzone, F. Melgrani, "Image thresholding based on the EM algorithm and the generalized Gaussian distribution", *Pattern Recognition* 40, pp. 619-634, 2007.
- [141] A.P. Dempster, N.M. Laird, D.B. Rubin, "Maximum-likelihood from incomplete data via the EM algorithm", *J. R. Stat. Soc. Ser. B Stat. Methodol.* 39 (1), pp. 1-38, 1977.
- [142] S-K.S. Fan, Y. Lin, "A fast estimation method for the generalized Gaussian mixture distribution on complex images", *Computer Vision and Image Understanding* 113, pp. 839-853, 2009.
- [143] H. Zhang, J.E. Fritts, S.A. Goldman, "Image segmentation evaluation: A survey of unsupervised methods", *Computer Vision and Image Understanding* 110, pp. 260-280, 2008.

- [144] L. Kunttu, "Shape and gray level descriptors for surface defect image retrieval and classification", Doctor of Technology Thesis, Tampere University of Technology, 2005.
- [145] M.K. Hu, "Visual Pattern Recognition by Moments Invariants", IRE Trans. Info. Theory 8, 1962.
- [146] S. Barrat, "Modèles graphiques probabilistes pour la reconnaissance des formes", Thèse de doctorat, Université Nancy 2, 2009.
- [147] T. Hastie, R. Tibshirani, J. H. Friedman, "The elements of statistical learning", Springer, 2001.
- [148] S. Tabbone, L. Wendling, J.-P. Salmon, "A new shape descriptor defined on the Radon transforms", Computer Vision and Image Understanding 102(1), pp. 42-51, 2006.
- [149] P.L. Rosin, "Measuring rectangularity", Mach. Vision Appl. 11(4), pp. 191-196, 1999.
- [150] M.R. Teague, "Image Analysis via the General Theory of Moments", Journal of the Optical Society of America 70(8), pp. 920-930, 1979.
- [151] C.H. Teh, R.T. Chin, "On image analysis by the method of moments", IEEE Trans. Pattern Analysis and Machine Intelligence 10, 1988.
- [152] J.J. Rocchio Jr., "Relevance feedback in information retrieval". In The SMART Retrieval System: Experiments in Automatic Document Processing, G. Salton, Ed. Englewood Cliffs, NJ: Prentice-Hall, pp. 313-323, 1971.
- [153] I.J. Cox, M.L. Miller, T.P. Minka, T.V. Papatomas, P.N. Yianilos, "The bayesian image retrieval system, PicHunter: Theory, implementation and psychophysical experiments", IEEE Trans. on Image Processing 9(1), pp. 20-37, 2000.
- [154] L. Zhang, F. Lin, B. Zhang, "Support vector machine learning for image retrieval", International Conference in Image Processing (ICIP'01), Greece, pp. 721-725, 2001.
- [155] J. Fournier, "Indexation d'images par le contenu et recherche interactive dans les bases généralistes", Thèse de doctorat, Université de Cergy-Pontoise, 2002.
- [156] Y. Rui, T.S. Huang, S. Mehrotra, "Content-based image retrieval with relevance feedback in MARS", IEEE International Conference on Image Processing (ICIP'97), pp. 815-818, 1997.
- [157] S. Newsam, G. Sumengen, B.S. Manjunath, "Category based image retrieval", International Conference in Image Processing (ICIP'01), Greece, pp. 596-599, Oct. 2001.
- [158] Heinrichs, D. Koubaroulis, B. Levienaise-Obadia, P. Rovida, J.M. Jolion, "Image indexing and content based search using preattentive similarities", RIAO 2000, Paris, pp. 1616-1631, 2000.