



HAL
open science

**DEFINITION ET ETUDE DES PERFORMANCES
D'UN DETECTEUR DE STRUCTURES
CURVILINEAIRES. APPLICATION A LA
STEREOSCOPIE ET LA DETECTION D'OBJETS
FILAIRES**

Cedric Lemaitre

► **To cite this version:**

Cedric Lemaitre. DEFINITION ET ETUDE DES PERFORMANCES D'UN DETECTEUR DE STRUCTURES CURVILINEAIRES. APPLICATION A LA STEREOSCOPIE ET LA DETECTION D'OBJETS FILAIRES. Interface homme-machine [cs.HC]. Université de Bourgogne, 2008. Français. NNT: . tel-00603569

HAL Id: tel-00603569

<https://theses.hal.science/tel-00603569>

Submitted on 26 Jun 2011

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

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



UNIVERSITÉ DE BOURGOGNE

U.F.R. SCIENCES ET TECHNIQUES
ÉCOLE DOCTORALE ENVIRONNEMENT SANTE/STIC



LE2I – UMR 5158



Thèse

Présentée et soutenue publiquement pour l'obtention du diplôme de

Docteur de l'université de Bourgogne

Spécialité : Instrumentation et Informatique de l'Image

par

Cédric Lemaître

Le 14 novembre 2008

**DEFINITION ET ETUDE DES PERFORMANCES D'UN
DETECTEUR DE STRUCTURES CURVILINEAIRES.
APPLICATION A LA STEREOSCOPIE ET LA DETECTION
D'OBJETS FILAIRES**

Directeurs de thèse : J. MITERAN

JURY

| | | |
|---------------|-----------------|--|
| Rapporteurs : | M. M. Desvignes | PR - Grenoble INP - Phelma - Grenoble - France |
| | M. C. Ducottet | PR - Université de Jean Monnet - St Etienne - France |
| Examineurs : | M. F. Marzani | MCF HDR - Université de Bourgogne - Dijon - France |
| | M. J. Mitéran | PR - Université de Bourgogne - Dijon - France |
| | M. S. Weber | PR - Université Henri Poincaré - Nancy - France |

Remerciements

Je tiens en premier lieux à remercier mon directeur de thèse, Monsieur Johel Mitéran, professeur à l'Université de Bourgogne, pour m'avoir accueilli et guidé avec attention et gentillesse pendant ces trois années. Ses qualités scientifiques et humaines, ses remarques ont largement contribué à l'aboutissement de cette thèse.

Je voudrais également remercier Messieurs Jiri Matas et Michal Perdoch du CMP (Prague – République Tchèque) pour leurs conseils et le temps qu'ils m'ont consacré lors de des différents séjours de recherche organisés dans le cadre de la collaboration entre le laboratoire Le2i et le CMP

Je remercie tous particulièrement Monsieur Michel Desvignes, Professeur à l'INPG de Grenoble ainsi que Monsieur Christophe Ducottet, Professeur à l'Université Jean Monnet de Saint Etienne qui ont accepté de juger ce travail et d'en être les rapporteurs.

Mes remerciements s'adressent aux membres de Jury qui me font l'honneur de participer à la soutenance.

Je tiens à témoigner toute mon amitié à Féthi Smach, et Khalil Khattab, avec qui j'ai partagé le bureau pendant ces trois années, et avec qui j'ai eu tant de discussions fructueuses. Je tiens à remercier profondément l'ensemble des membres du laboratoire Le2i, pour leur accueil chaleureux durant toutes ces années.

Enfin Je ne pourrais jamais oublier le soutien et l'aide de ma famille notamment ma femme, Véronique et mon Fils, Julian.

Dédicace

A Véronique et Julian
A mes parents et mon frère
A ma famille
A tous ceux qui me sont chers

TABLE DES MATIERES

| | |
|--|-----------|
| INTRODUCTION | 6 |
| CHAPITRE 1. DETECTION DE REGIONS D'INTERETS – LE CAS DES REGIONS CURVILINAIRES 12 | |
| 1.1. INTRODUCTION | 13 |
| 1.2. L'ESPACE D'ECHELLE | 14 |
| 1.3. LES DETECTEURS GENERALISTES | 15 |
| 1.3.1. <i>SIFT</i> | 15 |
| 1.3.2. <i>Harris-Affine et Hessian-Affine</i> | 16 |
| 1.3.3. <i>EBR</i> | 20 |
| 1.3.4. <i>IBR</i> | 21 |
| 1.3.5. <i>MSER</i> | 22 |
| 1.3.6. <i>PCBRD</i> | 24 |
| 1.4. METHODES DE RECONNAISSANCE DE FORMES UTILISANT LES CONTOURS POUR OBTENIR DES REGIONS D'INTERET | 26 |
| 1.5. LES DETECTEURS DE LIGNES GENERALISEES ET DE REGIONS CURVILINEAIRES | 30 |
| 1.5.1. <i>Méthodes basées sur des critères purement locaux</i> | 31 |
| 1.5.2. <i>Méthodes d'extraction utilisant la géométrie des régions curvilinéaires</i> | 33 |
| 1.5.3. <i>Méthodes d'extraction utilisant les méthodes de filtrage</i> | 35 |
| 1.5.4. <i>Méthode utilisant un modèle pour la détection de région curvilinéaire</i> | 37 |
| 1.5.5. <i>Détecteurs de régions curvilinéaires spécifiquement adaptés à la détection des veines de la rétine</i> | 39 |
| CHAPITRE 2. DEFINITION D'UN DETECTEUR DE REGIONS CURVILINEAIRES | 42 |
| 2.1. OBSERVATIONS | 43 |
| 2.2. PRESENTATION DU MODELE | 46 |
| 2.2.1. <i>Structures Curvilinéaires : définition</i> | 46 |
| 2.2.2. <i>Régions curvilinéaires : définition</i> | 47 |
| 2.2.3. <i>Section : définition</i> | 48 |
| 2.2.4. <i>Régions curvilinéaires : définition de contraintes 2D et détermination des régions</i> 52 | 52 |
| 2.3. IMPLEMENTATION DU DETECTEUR | 54 |
| 2.4. CONCLUSION | 57 |
| CHAPITRE 3. PERFORMANCES ET APPLICATIONS DE LA PHASE DE PRE-SEGMENTATION 58 | |
| 3.1. INTRODUCTION | 59 |
| 3.2. ETUDE DU DETECTEUR DE SECTION (SIGNAUX 1D) | 59 |
| 3.2.1. <i>Signaux de synthèse</i> | 59 |
| 3.2.2. <i>Signaux réels</i> | 65 |
| 3.2.3. <i>Stabilité du détecteur de section</i> | 68 |
| 3.3. PERFORMANCES DE LA PHASE DE PRE-SEGMENTATION (SIGNAUX 2D) | 73 |
| 3.3.1. <i>Etude sur des images de synthèse</i> | 73 |
| 3.3.2. <i>Comparaison qualitative avec Steger sur des images réelles</i> | 76 |
| 3.3.3. <i>Comparaison quantitative – images de la rétine</i> | 85 |
| 3.4. APPLICATIONS DE LA PHASE DE PRE-SEGMENTATION | 91 |

| | | |
|---|--|------------------------------------|
| 3.4.1. | <i>Détection de cordons de colle</i> | 91 |
| 3.4.2. | <i>Détection de l'aorte dans les images IRM</i> | 93 |
| CHAPITRE 4. DESCRIPTEURS GENERALISTES ET DESCRIPTEURS DE REGIONS CURVILINEAIRES | | 96 |
| 4.1. | INTRODUCTION..... | 97 |
| 4.2. | LES DESCRIPTEURS GENERALISTES..... | 97 |
| 4.2.1. | <i>SIFT</i> | 97 |
| 4.2.2. | <i>PCA-SIFT</i> | 98 |
| 4.2.3. | <i>GLOH</i> | 98 |
| 4.2.4. | <i>SURF</i> | 99 |
| 4.2.5. | <i>Spin images</i> | 100 |
| 4.2.6. | <i>Invariants différentiels</i> | 100 |
| 4.2.7. | <i>Steerable filters</i> | 101 |
| 4.2.8. | <i>Filtres complexes</i> | 101 |
| 4.2.9. | <i>Descripteurs basés sur les moments</i> | 102 |
| 4.2.10. | <i>Les descripteurs généralisés de Fourier</i> | 103 |
| 4.2.11. | <i>Shape context</i> | 106 |
| 4.3. | LES DESCRIPTEURS DE TYPE SHAPE CONTEXT ADAPTES AUX REGIONS CURVILINEAIRES | 107 |
| CHAPITRE 5. REPETABILITE ET ROBUSTESSE DE LA DETECTION DES REGIONS CURVILINEAIRES APPLIQUEE A LA MISE EN CORRESPONDANCE.. | | 110 |
| 5.1. | METHODOLOGIE..... | 111 |
| 5.2. | CRITERE D'EVALUATION..... | 111 |
| 5.2.1. | <i>Critères d'évaluation existants</i> | 111 |
| 5.2.2. | <i>Critères d'évaluation du détecteur de régions curvilinéaires</i> | 112 |
| 5.3. | EVALUATION DE L'INFLUENCE DES PARAMETRES DU CRD..... | 114 |
| 5.4. | EVALUATION DE L'INFLUENCE DU GRADIENT CALCULE DANS L'ESPACE DE FOURIER SUR LES PERFORMANCES DE MISE EN CORRESPONDANCE..... | 115 |
| 5.5. | ROBUSTESSE DU DETECTEUR..... | 118 |
| 5.5.1. | <i>Changement de point de vue</i> | 119 |
| 5.5.2. | <i>Changement d'échelle</i> | 120 |
| 5.5.3. | <i>Sensibilité au flou</i> | 122 |
| 5.5.4. | <i>Changement d'intensité d'éclairage</i> | 124 |
| 5.5.5. | <i>Compression JPEG</i> | 126 |
| 5.6. | ESTIMATION D'HOMOGRAPHIES..... | 127 |
| 5.6.1. | <i>Méthodologie</i> | 127 |
| 5.6.2. | <i>Résultats</i> | 129 |
| 5.7. | DISCUSSION DES RESULTATS..... | 132 |
| CONCLUSION | | 134 |
| ANNEXE 1 : EVALUATION DE L'INFLUENCE DES PARAMETRES DU CRD | | 139 |
| ANNEXE 2 : ARCHITECTURE MATERIELLE POUR LA RECONNAISSANCE VIDEO TEMPS-REEL UTILISANT UNE APPROXIMATION DES MOMENTS DE ZERNIKE ET DES SVM | | 145 |
| BIBLIOGRAPHIE | | ERREUR ! SIGNET NON DEFINI. |

TABLE DES FIGURES

| | |
|---|----|
| FIGURE 1 : METHODOLOGIE GENERALE | 7 |
| FIGURE 2 : EXEMPLE D'IMAGES COMPORTANT DES STRUCTURES CURVILINEAIRES | 8 |
| FIGURE 3 : METHODOLOGIE APPLIQUEE | 9 |
| FIGURE 4 : CONSTRUCTION DE L'OPERATEUR DOG AU SEIN DE L'ESPACE D'ECHELLE | 15 |
| FIGURE 5 : ILLUSTRATION DE LA NORMALISATION AFFINE | 19 |
| FIGURE 6 EXEMPLE DE CONSTRUCTION D'UNE REGION D'INTERET DE TYPE EBR..... | 21 |
| FIGURE 7 ILLUSTRATION DE LA METHODE D'EXPLORATION DE IBR..... | 22 |
| FIGURE 8 : ILLUSTRATION DES RESULTATS DE PCBRD. (A) IMAGE ORIGINALE. (B) IMAGE DES COURBURES PRINCIPALES. (C) IMAGES DES COURBURES PRINCIPALES « NETTOYEES ». (D) REGIONS ISSUES DE L'ALGORITHME DE LIGNES DE PARTAGES DES EAUX ET (E) REGIONS FINALES | 25 |
| FIGURE 9 : EXEMPLE DE RESULTATS OBTENUS PAR LA METHODE DE K. MIKOLAJCZYK | 28 |
| FIGURE 10 : EXEMPLE DE RESULTATS DE LA METHODE CARMICHAEL | 30 |
| FIGURE 11 : EXEMPLE D'OBJET MAL DECRITS PAR LES DETECTEURS LOCAUX STANDARDS. (ICI UN HESSIEN-AFFINE)..... | 31 |
| FIGURE 12 : OBSERVATION DES PROPRIETES D'UNE SECTION D'UNE REGION | 43 |
| FIGURE 13 : ILLUSTRATION DE LA CONSERVATION DE LA LARGEUR D'UNE REGION CURVILINEAIRE SUR L'ENSEMBLE DE SA LONGUEUR | 44 |
| FIGURE 14 : ILLUSTRATION DE L'EVOLUTION DE LA COURBURE LOCALE LE LONG DES REGIONS CURVILINEAIRES | 45 |
| FIGURE 15 : DEFINITION DU SYSTEME DE COORDONNEES ET D'UNE SECTION | 46 |
| FIGURE 16 : DEFINITION D'UNE REGION | 48 |
| FIGURE 17 : SECTION DANS LE SYSTEME DE COORDONNEES LOCALES | 49 |
| FIGURE 18 : TACHES PRINCIPALES DU DETECTEUR DE REGIONS CURVILINEAIRES..... | 55 |
| FIGURE 19 : DETAILS DE L'ANALYSE 2D | 56 |
| FIGURE 20 : REPONSE DU DETECTEUR DE SECTION POUR LE SIGNAL "PORTE IDEALE" (SYMETRIQUE ET ASYMETRIQUE)..... | 60 |
| FIGURE 21 : REPONSE DU DETECTEUR POUR LE MODELE DE LIGNE PROPOSE PAR STEGER | 61 |
| FIGURE 22 : RESULTATS DE NOTRE DETECTEUR POUR UN PROFIL DE LIGNE "TRIANGULAIRE" | 62 |
| FIGURE 23 : RESULTATS DU DETECTEUR POUR LE SIGNAL "RAMPE" | 63 |
| FIGURE 24 : SIGNAL CONTENANT DEUX TEXTURES DE MEME AMPLITUDE ET REPONSE DU DETECTEUR | 64 |
| FIGURE 25 : RESULTATS DE LA CONVOLUTION DE DERIVEES PREMIERES ET SECONDES DE GAUSSIENNE PROPOSEES PAR STEGER SUR LE SIGNAL CONTENANT 2 TEXTURES | 64 |
| FIGURE 26 : ILLUSTRATION DE LA SELECTION D'UN SIGNAL AU SEIN DE L'IMAGE DE LA RETINE ET REPONSE DU DETECTEUR DE SECTION | 65 |
| FIGURE 27 : RESULTATS DE LA CONVOLUTION AVEC LA DERIVEE PREMIERE D'UNE GAUSSIENNE.. | 66 |
| FIGURE 28 : ILLUSTRATION DE LA SELECTION DES SIGNAUX AU SEIN D'UNE IMAGE AERIENNE | 66 |
| FIGURE 29 : REPONSE DU DETECTEUR POUR LA COUPE CONTENANT UNE ROUTE BORDEE DE DEUX TEXTURES SIMILAIRE (A) ET DE DEUX TEXTURES DIFFERENTES (B). | 67 |
| FIGURE 30 : RESULTATS DE LA CONVOLUTION DE LA DERIVEE PREMIERE D'UNE GAUSSIENNE AVEC UN SIGNAL CONTENANT UNE ROUTE BORDEE DE TEXTURES SIMILAIRES (A ET B) ET DEUX TEXTURES DIFFERENTES (C ET D). | 68 |
| FIGURE 31 : IMAGES UTILISEES POUR L'ETUDE DE L'INFLUENCE DU CHANGEMENT DE POINTS DE VUE SUR LE DETECTEUR DE SECTION | 69 |
| FIGURE 32 : EXEMPLE DE COUPE EXTRAITE AU NIVEAU DU PORTAIL | 70 |

| | |
|---|-----|
| FIGURE 33 : IMAGE DANS LAQUELLE UNE COUPE A ETE REALISEE POUR L'ETUDE DE L'INFLUENCE DU BRUIT SUR LE DETECTEUR DE SECTION | 71 |
| FIGURE 34 : EXEMPLE D'IMAGES UTILISEES POUR EVALUER L'INFLUENCE DU BRUIT NATUREL SUR LE DETECTEUR DE SECTION (A) ET AGRANDISSEMENTS (B) | 72 |
| FIGURE 35 : EXEMPLE DE RESULTATS DE SEGMENTATION SUR DES IMAGES DE SYNTHESE TRES SIMPLES | 74 |
| FIGURE 36 : IMAGE CONTENANT DEUX REGIONS CURVILINEAIRES TEXTUREES (A) ET LE RESULTAT DU DETECTEUR DE REGIONS CURVILINEAIRES AVEC CONTRAINTE DE VARIATION DE LARGEUR FAIBLE (B) AVEC CONTRAINTE DE VARIATION DE LARGEUR PLUS RESTRICTIVE (C) | 75 |
| FIGURE 37 : IMAGE POSSEDANT UNE REGION CURVILINEAIRE BORDE D'UN DEGRADE ET D'UNE REGION HOMOGENE (A), RESULTATS DU DETECTEUR DE REGIONS CURVILINEAIRES (B) ET RESULTATS DU DETECTEUR DE STEGER AVEC PRESENCE DE BIAIS (C)..... | 75 |
| FIGURE 38 : RESULTATS POUR UNE IMAGE COMPORTANT 2 REGIONS CURVILINEAIRES SUR FOND TEXTURE (A). POINTS DE CONTOURS UTILISES POUR INITIALISER LE DETECTEUR (B). RESULTATS DU DETECTEUR POUR UNE LARGEUR DE FFT DE 4 (C) ET 16 (D)..... | 76 |
| FIGURE 39 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 77 |
| FIGURE 40 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 78 |
| FIGURE 41 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 79 |
| FIGURE 42 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 80 |
| FIGURE 43 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 81 |
| FIGURE 44 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 82 |
| FIGURE 45 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 83 |
| FIGURE 46 : RESULTATS DE SEGMENTATION DU DETECTEUR DE STEGER ET DU CRD | 84 |
| FIGURE 47 COURBE ROC DES DIFFERENTES METHODES UTILISEES | 87 |
| FIGURE 48 : RESULTATS DE SEGMENTATION (A) IMAGE ORIGINALE (B) SEGMENTATION MANUELLE (C) CHAUDHURI (D) MARTINEZ-PEREZ (E) STAAL (F) CRD | 88 |
| FIGURE 49 : RESULTATS DE SEGMENTATION (A) IMAGE ORIGINALE (B) SEGMENTATION MANUELLE (C) CHAUDHURI (D) MARTINEZ-PEREZ (E) STAAL (F) CRD | 89 |
| FIGURE 50 : RESULTATS DE SEGMENTATION (A) IMAGE ORIGINALE (B) SEGMENTATION MANUELLE (C) CHAUDHURI (D) MARTINEZ-PEREZ (E) STAAL (F) CRD | 90 |
| FIGURE 51 : METHODES DE DETECTION DU CORDON ACTUELLEMENT UTILISEE..... | 91 |
| FIGURE 52 : EXEMPLE DE RESULTATS DE DETECTION AUTOMATIQUE DE CORDONS UTILISANT LE CRD | 92 |
| FIGURE 53 : DIFFERENTES PARTIES COMPOSANT L'AORTE (A) ET MESURE ACTUELLEMENT PRATIQUEE (B). | 93 |
| FIGURE 54 : EXEMPLE DE DETECTION DE L'AORTE : DETECTIONS CORRECTES (A), FAUSSES DETECTIONS (B) | 95 |
| FIGURE 55 : METHODOLOGIE GENERALE | 97 |
| FIGURE 56 : ILLUSTRATION DU PRINCIPE DE SIFT | 98 |
| FIGURE 57 : ILLUSTRATION DE LA GRILLE LOG-POLAIRE UTILISEE..... | 99 |
| FIGURE 58 : FILTRES GAUSSIENS PERMETTANT DE CALCULER LES DERIVEES NECESSAIRES A L'OBTENTION DES INVARIANTS DIFFERENTIELS | 100 |
| FIGURE 59 : FILTRE UTILISE POUR CALCULER LES INVARIANTS BASES SUR LES FILTRES COMPLEXES | 101 |
| FIGURE 60 : ILLUSTRATION DU CALCUL DES DESCRIPTEURS SUR LES CERCLES CONCENTRIQUES. | 103 |
| FIGURE 61 : PROTOCOLE D'EVALUATION DES DESCRIPTEURS | 104 |
| FIGURE 62 : EXEMPLE D'IMAGES DE LA BASE COIL..... | 105 |
| FIGURE 63 : EXEMPLE D'IMAGES DE LA BASE AR-FACE | 106 |
| FIGURE 64 : PRINCIPE DE CALCUL DU CRSD | 108 |

| | |
|---|-----|
| FIGURE 65 : "CURVILINEAR REGION SHAPE DESCRIPTOR". (A) POINT DE L'AXE DES REGIONS CURVILINEAIRES (1/5). (B) PRE-SEGMENTATION, TOUS LES POINTS JAUNES PRESENTENT DES CARACTERISTIQUES SIMILAIRES. (C) GRILLE « LOG-POLAIRE » DU DESCRIPTEUR..... | 109 |
| FIGURE 66: PAIRES D'IMAGES UTILISEES POUR DETERMINER L'INFLUENCE DE λ SUR LES PERFORMANCES DE MISE EN CORRESPONDANCE | 117 |
| FIGURE 67 : IMAGES UTILISEES POUR L'EVALUATION DE L'INFLUENCE DU CHANGEMENT DE POINT DE VUE SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES | 119 |
| FIGURE 68 : INFLUENCE DU CHANGEMENT DE POINT DE VUE SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES ET DES DETECTEURS STANDARDS | 119 |
| FIGURE 69 : IMAGES UTILISEES POUR L'EVALUATION DE L'INFLUENCE DU CHANGEMENT D'ECHELLE SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES | 120 |
| FIGURE 70 : INFLUENCE DU CHANGEMENT D'ECHELLE SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES ET DES DETECTEURS STANDARDS | 121 |
| FIGURE 71 : IMAGES UTILISEES POUR L'EVALUATION DE L'INFLUENCE DU FLOU SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES | 122 |
| FIGURE 72 : INFLUENCE DU FLOU SUR LES PERFORMANCES DU CRD ET DES DETECTEURS STANDARDS | 122 |
| FIGURE 73 : IMAGES UTILISEES POUR EVALUER L'INFLUENCE DU CHANGEMENT DE D'ECLAIRE SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES..... | 124 |
| FIGURE 74 : INFLUENCE DE L'INTENSITE LUMINEUSE SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES ET DES DETECTEURS STANDARDS | 125 |
| FIGURE 75 : IMAGES UTILISEES POUR ETUDIER L'INFLUENCE DE LA COMPRESSION JPEG SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES | 126 |
| FIGURE 76 : INFLUENCE DE LA COMPRESSION JPEG SUR LES PERFORMANCES DU DETECTEUR DE REGIONS CURVILINEAIRES ET DES DETECTEURS STANDARDS | 126 |
| FIGURE 77 : ILLUSTRATION DE LA STRATEGIE DE MISE EN CORRESPONDANCE | 128 |
| FIGURE 78 : PRINCIPE DE L'ESTIMATION AUTOMATIQUE D'HOMOGRAPHIE..... | 129 |
| FIGURE 79 : ILLUSTRATION DE L'ESTIMATION AUTOMATIQUE D'HOMOGRAPHIES (LES INLIERS APPARAISSENT EN COULEUR) | 131 |
| FIGURE 80 : EXEMPLE DE PAIRES D'IMAGES POUR LESQUELLES LE CRD FONCTIONNE DE FAÇON MEDIOCRE (A) | 132 |
| FIGURE 81 : ILLUSTRATION DE LA COMBINAISON D'INFORMATION PROVENANT DES DETECTEURS "STANDARD" ET DU DETECTEUR DE REGIONS CURVILINEAIRES | 136 |
| FIGURE 82 : RESULTATS DE LA ROBUSTESSE A LA ROTATION..... | 147 |
| FIGURE 83 : RESULTATS DE LA ROBUSTESSE A L'AJOUT DE BRUIT | 147 |
| FIGURE 84: MODULE D'ESTIMATION DES MOMENTS DE ZERNIKE | 150 |

Introduction

Contexte général

De tous temps, l'homme a tenté d'élaborer des machines capables de reproduire son activité. L'évolution des connaissances et des techniques dans de nombreux domaines comme la physique, les mathématiques, la médecine et plus récemment l'informatique a permis de développer de nombreux d'outils, du plus rudimentaire robot mono-tache jusqu'aux systèmes intelligents les plus aboutis.

Les progrès en médecine et en neurosciences ont permis de mieux appréhender le système de vision humain et, depuis une quarantaine d'année, l'homme cherche à reproduire le mécanisme de cette vision en utilisant les moyens technologiques dont il dispose. Cette discipline, que nous désignons par *vision par ordinateur*, a pour applications, par exemple, le déplacement de robots autonomes, la vidéosurveillance et l'interprétation d'images provenant de satellites.

La vision par ordinateur s'articule autour de nombreuses thématiques, dont :

- La reconnaissance du relief qui vise à mesurer la distance entre la source d'acquisition et les objets afin d'être capable de les situer les uns par rapport aux autres,
- La reconnaissance de formes a pour but d'attribuer une étiquette correspondant à la catégorie, la classe, à tous les objets de l'image.

La reconnaissance de relief et la reconnaissance de formes nécessitent l'extraction automatique d'informations sur la structure de la scène et/ou des objets la constituant, pour pouvoir réaliser une reconstruction 3D de la scène ou/et réaliser une reconnaissance des objets de manière robuste.

L'extraction de zones caractéristiques – les structures ou régions curvilinéaires - que nous avons étudiées au cours de ce travail de thèse et que

nous présentons dans ce manuscrit, s'inscrit dans le contexte de ces deux thèmes.

Ces travaux de recherche ont été menés en collaboration avec le CMP (Center for Machine Perception - Prague - République Tchèque), et plus particulièrement avec J. Matas et M. Perdoch, avec lesquels le laboratoire Le2i entretient une collaboration de longue date.

Méthodologie générale

La méthodologie générale couramment employée pour la reconnaissance de formes ou l'estimation d'homographies à partir de points ou régions d'intérêt et de descripteurs est résumée sur la Figure 1.

Après d'éventuels prétraitements destinés à améliorer la qualité générale de l'image, un détecteur de régions ou points d'intérêt est appliqué. Pour chacun de ces points ou régions, on détermine ensuite un ensemble de descripteurs locaux qui vont permettre de caractériser les objets à analyser (reconnaître, localiser, etc). Si l'on dispose de deux ou plusieurs images de la même scène, l'analyse à réaliser peut également être par exemple l'estimation de l'homographie liant les deux images, ou encore la détermination de la géométrie épipolaire permettant d'envisager une reconstruction 3D complète.

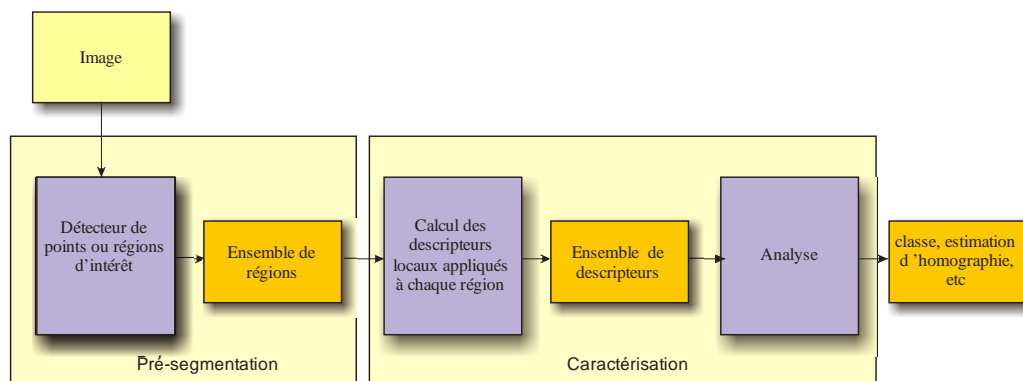


Figure 1 : Méthodologie générale

Une des opérations de base mises en œuvre dans ces méthodes est la mise en correspondance entre régions. Or la qualité de cette mise en correspondance peut être améliorée en prenant en compte les aspects caractéristiques de régions comme les régions curvilinéaires. En effet, de nombreux détecteurs de points ou régions d'intérêt ont été étudiés dans la littérature ces dernières

années. Dans de nombreux cas, ils donnent satisfaction par leur robustesse et leur répétabilité. Toutefois, il existe de nombreux cas d'images réelles pour lesquels ces détecteurs (et parfois les descripteurs avec lesquels ils ont été associés) ne sont pas les plus adaptés.

Structures curvilinéaires et méthodologie envisagée

Nous avons représenté Figure 2 quelques exemples d'images dans lesquelles nous trouvons des régions curvilinéaires, c'est-à-dire des formes allongées, dont la largeur est approximativement constante et la texture interne est également constante. Ces types de régions sont présents dans un grand nombre de domaines applicatifs potentiels, et sont suffisamment caractéristiques pour qu'il soit intéressant de définir un détecteur spécifique et de vérifier sa répétabilité.




Figure 2 : Exemple d'images comportant des structures curvilinéaires

En imagerie médicale, on pense bien évidemment aux veines (images de la rétine, ou encore des clichés provenant d'imageur de type IRM de l'aorte

thoracique). En imagerie aérienne ou satellitaire, on trouve essentiellement les routes, les rivières. En ce qui concerne les images du contexte automobile, les lignes blanches, les poteaux de signalisation, les troncs d'arbres sont autant de formes qui répondent à des critères communs.

Plus généralement, de nombreux objets construits par l'homme sont réalisés à partir de structures tubulaires ou filaires, comme les bicyclettes, les portails, clôtures, etc.

Le but de ce travail de thèse a donc été de montrer que ces régions curvilinéaires, très souvent présentes dans les images, peuvent être détectées de manière stable et robuste, de la même manière que d'autres régions plus généralistes, et être utilisées dans les opérations de mise en correspondance afin d'augmenter les performances d'opérations telles que l'estimation d'homographie. Nous avons donc été amenés à définir un modèle puis un détecteur de ces structures, en nous basant sur l'état de l'art dans ce domaine, notamment les travaux de Steger [Steger, C. 1998a ; Steger, C. 1998b], et en apportant plusieurs contributions, dans les traitements bas niveau aussi bien que dans ceux de plus haut niveau, puis à définir un descripteur adapté destiné à la phase de mise en correspondance proprement dite.

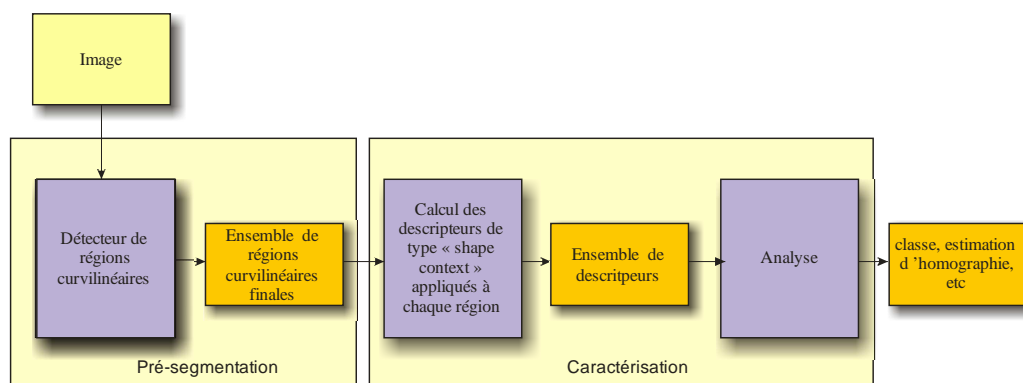


Figure 3 : Méthodologie appliquée

Nous suivrons donc la méthodologie du cadre général en appliquant un détecteur particulier, le détecteur de formes ou régions curvilinéaires (que nous nommerons CRD par la suite), suivi de l'extraction de descripteurs qui permettront d'envisager différentes applications, comme la segmentation et l'estimation d'homographies (Figure 3). Le CRD permet en effet de réaliser une phase de pré-segmentation, éliminant le « fond », et permettant de ne

conserver que les points de ces régions ou les contours qui les composent. Ceci nous permettra d'obtenir une très bonne invariance au changement de point de vue, au changement d'échelle, tout en ayant une bonne robustesse aux perturbations que représentent le bruit, la présence de flou, les changements de luminosité, la compression JPEG.

Organisation de la thèse et principales contributions

Les principales contributions de ce travail se situent à trois niveaux :

- La définition et mise en œuvre d'un détecteur (CRD) de régions curvilinéaires les plus répétables possible, le détecteur couvrant une large classe de problèmes, et l'évaluation de ses performances pour la phase de pré-segmentation,
- La définition des descripteurs de type « shape context », en collaboration avec les travaux de thèse de Michal Perdoch, au CMP (République Tchèque) permettant de caractériser au mieux les régions curvilinéaires,
- L'évaluation de la répétabilité et de la robustesse de la détection de ces régions et leur apport aux opérations de mise en correspondance, détection finalement appliquée à l'estimation d'homographies ou à la pré-segmentation d'images, notamment d'images IRM d'aortes thoraciques.

Pour répondre aux problématiques présentées précédemment, ce manuscrit s'articule autour de cinq chapitres :

Dans le premier chapitre, nous présentons dans les détecteurs de régions et de points d'intérêt « standards » présents dans la littérature. Ces détecteurs sont en effet majoritairement utilisés dans les applications de mise en correspondance depuis une dizaine d'années, application principale potentielle du détecteur proposé dans cette thèse. Cette première partie conduit à la conclusion qu'aucun des ces détecteurs ne permet d'extraire spécifiquement les régions curvilinéaires. Pour ces raisons et dans le but de construire un détecteur de régions d'intérêt permettant d'utiliser les régions curvilinéaires, nous dressons un état de l'art des méthodes de détection des régions curvilinéaires.

Dans le second chapitre, nous proposons un modèle pour la détection de régions curvilinéaires, que nous souhaiterons adapté aux opérations de mise en correspondance. Ce modèle est séparé en deux parties. Dans une première partie, nous définissons un détecteur de section de formes curvilinéaires. Dans un second temps, nous introduisons un processus complet de détection de structures curvilinéaires.

Le troisième chapitre est consacré à l'évaluation du détecteur de section et du détecteur global. Dans un premier temps, les performances du détecteur de section sont évaluées qualitativement sur différents signaux de synthèse et réels. Des résultats quantitatifs, de l'évaluation de la robustesse du détecteur de section au bruit, sont également présentés. Dans un second temps, les performances de pré-segmentation (séparation premier plan – arrière plan) du détecteur dans son ensemble sont présentées. Ces performances sont évaluées qualitativement et comparé au détecteur de Steger [Steger, C. 1998a ; Steger, C. 1998b]. Nous évaluons ensuite quantitativement et comparons les performances du détecteur global par rapport à des méthodes développées dans la cadre de la segmentation de veines de la rétine.

Enfin nous présentons deux applications potentielles de la phase de pré-segmentation. La première application est la détection de cordons de colle présents sur les culasses de voitures avant montage. La seconde application est la détection de l'aorte au sein d'images provenant d'imageur IRM.

Dans un quatrième chapitre, nous dressons un état de l'art des techniques de caractérisation, description, de régions d'intérêts. Cet état de l'art nous amène à conclure qu'aucune des techniques actuelles permettent de caractériser les régions curvilinéaires. Pour ces raisons, nous définissons dans la suite de ce chapitre un descripteur spécifiquement lié à la description de ces régions.

Le cinquième et dernier chapitre est consacré à l'évaluation des performances des différents opérateurs proposés dans le cadre des opérations de mise en correspondance. Nous introduisons dans un premier temps les différents critères d'évaluations puis nous menons une étude qualitative en suivant le protocole d'évaluation des performances des détecteurs de régions d'intérêt de Mikolajczyk [Mikolajczyk, K. & al : 2005b]. Enfin, nous présentons une application d'estimation automatique d'homographies utilisant les régions curvilinéaires et le descripteur associé.

Chapitre 1. Détection de régions d'intérêts – Le cas des régions curvilinaires

1.1. Introduction

L'utilisation des régions d'intérêt prend une part croissante dans les applications de vision par ordinateur. Elles jouent un rôle crucial dans les applications de mise en correspondances comme :

- La stéréovision,
- La reconnaissance de forme,
- Le tracking,
- L'indexation d'image et de vidéo,
- L'aide à la navigation.

L'idée commune à toutes ces applications est la recherche de mise en correspondance de régions entre deux images ou plus. L'utilisation de régions d'intérêt, par opposition aux méthodes prenant en compte l'image dans sa globalité, a été motivée par le fait qu'une région de faible taille est moins sujette aux occlusions qu'une zone de forte taille. Il est plus aisé de mettre en correspondance une petite zone d'une image que l'image dans son intégralité. D'autre part, ces régions permettent la localisation d'objet dans une scène à fond complexe, ou encore la reconnaissance de plusieurs objets dans une même image.

Cependant, pour que la mise en correspondance soit possible, les régions d'intérêt détectées doivent présenter quelques propriétés importantes. Elles doivent notamment être répétables face aux transformations affines (rotations, translation, changements d'échelle) ainsi qu'aux changements de point de vue et aux conditions d'éclairage. De plus, l'information contenue au sein de la région doit posséder un pouvoir discriminant important.

Dans la suite de ce chapitre nous présenterons les principaux détecteurs de régions d'intérêts utilisés actuellement. Nous nous intéresserons ensuite plus particulièrement à différentes méthodes de détections des régions d'intérêt dites : « curvilinéaires » désignées par certains auteurs par le terme : « lignes généralisées ». En effet les éléments curvilignes contenus dans les images sont bien souvent délaissés par les détecteurs actuels alors qu'ils peuvent apporter une contribution non négligeable au processus de mise en correspondance.

1.2. L'espace d'échelle

A titre de préliminaire, nous allons définir la notion d'espace échelle utilisée par quelques uns des détecteurs de régions d'intérêt étudiés.

La notion d'espace échelle introduite sous sa forme continue par Koenderink [Koenderink, J. J. & al : 1994] permet d'obtenir les dérivées d'une image en utilisant des arguments de géométrie différentielle. En particulier, il a été établi par Koenderink [Koenderink, J. J. & al : 1994] et par Lindeberg [Lindeberg, T. 1997] que le seul opérateur isotrope possible de l'espace d'échelle linéaire, sous des conditions raisonnables, est l'opérateur gaussien.

Une définition de l'espace d'échelle pour les signaux monodimensionnels (que nous noterons par la suite 1D) est la suivante [SIDIBE, D. D. 2007] :

Soit $f(x)$ une fonction et $G_\sigma(x)$ la gaussienne d'écart-type σ . On appelle espace d'échelle, le lieu des réalisations de la transformation S définie ci dessous :

$$(Sf)(x, \sigma) = f * G_\sigma(x)(x, \sigma) \in \mathbb{R} \times \mathbb{R}^+ \quad (2.1)$$

l'on notera $E = (x, \sigma)$ l'espace échelle.

Cette transformation conduit à la représentation d'une fonction sous la forme d'une surface décrite dans E . On peut donc étudier cette surface en utilisant des arguments de géométrie différentielle.

La représentation dans l'espace échelle d'une image $I(x, y)$ est donc définie par une fonction $E(x, y, \sigma)$, obtenue par la convolution I de avec une gaussienne $G(x, y, \sigma)$ d'écart-type variable :

$$E(x, y, \sigma) = G(x, y, \sigma) * I(x, y)$$

Où $*$ est l'opérateur de convolution et $G(x, y, \sigma)$ la fonction gaussienne définie par :

$$G(x, y, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\left(\frac{x^2+y^2}{2\sigma^2}\right)} \quad (2.2)$$

1.3. Les détecteurs généralistes

1.3.1. SIFT

L'approche de D. Lowe [Lowe, D. 1999 ; Lowe, D. 2004] est considérée par beaucoup comme une des plus génériques et performantes. Ce détecteur est désigné par l'acronyme SIFT pour Scale Invariant Feature Transform. La version initiale de SIFT décrite dans [Lowe, D. 1999] est composée d'un détecteur de points d'intérêt invariants aux changements d'échelle ainsi qu'un descripteur robuste qui sera décrit en détail par la suite (voir chapitre 3).

L'idée principale de la partie détecteur de cet opérateur est de repérer des points dans l'image qui sont stables à l'intérieur de l'espace d'échelle. On va donc pour cela utiliser les extremums locaux de l'opérateur DoG (Difference of Gaussian) au sein de l'espace d'échelle. On définit l'opérateur DoG entre deux échelles consécutives séparées par une constante multiplicative k par :

$$DoG(x, y) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) \quad (2.3)$$

Où σ est l'écart-type de la gaussienne et x, y les coordonnées dans l'image.




Figure 4 : Construction de l'opérateur DoG au sein de l'espace d'échelle

Cet opérateur possède la caractéristique d'être très rapide à calculer car il est déterminé à partir de simples soustractions. D'un point de vue de l'implémentation, chaque octave de l'espace d'échelle (doublement de σ) est divisée en un nombre d'intervalles k . On va ensuite soustraire les images adjacentes pour obtenir les images de différences de gaussiennes : *DoG* (voir Figure 4). Lowe montre expérimentalement que les résultats les plus stables sont obtenus pour un nombre d'intervalles égal à 3.

A partir de ces images de différences de gaussiennes, il reste à déterminer les points d'intérêt. Pour cela chaque point d'une image *DoG* est comparé à ses huit voisins les plus proches ainsi qu'à ses huit voisins les plus proches pour l'échelle directement supérieure et l'échelle directement inférieure. De cette manière, il est alors possible de détecter les minima et maxima locaux.

Enfin, il faut noter que le détecteur de points d'intérêt de Lowe n'est pas invariant aux transformations affines. Cependant le descripteur associé permet d'obtenir de bons résultats en cas de changement de point de vue [Mikolajczyk, K. & al : 2005b].

Le détecteur SIFT est actuellement utilisé dans bon nombre d'applications, notamment de reconnaissance de formes [Lowe, D. 2004], de recherche d'images par le contenu [Gao, K. & al : 2008] ou encore pour l'estimation de la géométrie épipolaire [Goshen, L. & al : 2008]

1.3.2. Harris-Affine et Hessien-Affine

Nous allons décrire ici deux méthodes permettant de détecter des points d'intérêts au sein de l'espace d'échelle. Des régions de formes elliptiques seront déterminées à partir de ces points.

Ces points d'intérêt sont détectés en utilisant le détecteur de Harris ou à l'aide d'un détecteur basé sur l'interprétation de la matrice du Hessien. Dans les deux cas, la sélection d'échelle est basée sur l'opérateur laplacien et la forme des régions elliptiques est déterminée utilisant la matrice des moments du second ordre de l'intensité du gradient [Baumberg, A. 2000 ; Lindeberg, T. 1997].

Les matrices des moments du second ordre, aussi appelées matrices d'auto-corrélation, sont souvent utilisées pour la détection de caractéristiques ou pour décrire les structures locales au sein des images. Le détecteur de Harris-Affine utilise ces matrices mais aussi l'opérateur d'estimation de la forme des

régions elliptiques. Ces matrices qui décrivent la distribution du gradient dans le voisinage local d'un point sont définies de la manière suivante :

$$M = \mu(x, y, \sigma_l, \sigma_D) = \begin{bmatrix} \mu_{11} & \mu_{12} \\ \mu_{21} & \mu_{22} \end{bmatrix} \quad (2.4)$$

Où μ sont les moments de l'image.

$$M = \sigma_D^2 G(\sigma_l) * \begin{bmatrix} I_x^2(x, y, \sigma_D) & I_x I_y(x, y, \sigma_D) \\ I_x I_y(x, y, \sigma_D) & I_y^2(x, y, \sigma_D) \end{bmatrix} \quad (2.5)$$

Les dérivées locales I_x et I_y sont calculées avec des noyaux gaussiens dans une fenêtre de taille $\sigma_D \times \sigma_D$. Les dérivées sont alors moyennées dans le voisinage du point en lissant avec une fenêtre gaussienne d'échelle σ_l . Les valeurs propres de la matrice M représentent des modifications du signal dans le voisinage du point. Cette propriété permet l'extraction de points pour lesquels les courbures sont importantes, c'est-à-dire aux endroits où des changements significatifs du signal se produisent. Les points retenus selon ce principe sont stables dans des conditions arbitraires d'éclairage et, d'après Lowe, sont représentatifs de l'image. Le détecteur de points d'intérêt de Harris [Harris, C. & al : 1988] est également basé sur ce principe.

Une idée similaire est explorée dans le détecteur basé sur l'interprétation de la matrice du Hessien :

$$H = H(x, y, \sigma_D) = \begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix} \quad (2.6)$$

$$H = \begin{bmatrix} I_{xx}(x, y, \sigma_D) & I_{xy}(x, y, \sigma_D) \\ I_{xy}(x, y, \sigma_D) & I_{yy}(x, y, \sigma_D) \end{bmatrix} \quad (2.7)$$

Les dérivées secondes utilisées dans cette matrice donnent des réponses importantes dans des structures comme les « bulles » et les crêtes.

Ces régions sont similaires à celles détectées par l'opérateur Laplacien [Lindeberg, T. 1998] [Lowe, D. 1999]. Cependant une fonction basée sur le déterminant de la matrice du Hessien pénalise les très longues structures pour lesquels la dérivée seconde sur une de ses orientations est vraiment faible

[Deng, H. & al : 2007]. Un minimum local du déterminant de cette matrice indique la présence d'une structure de type « bulle ».

Pour obtenir l'invariance aux changements d'échelle, une méthode de sélection est appliquée. L'idée est de sélectionner l'échelle caractéristique de la structure locale pour laquelle une fonction donnée atteint un extremum en fonction de l'échelle. L'échelle ainsi sélectionnée est caractéristique au sens quantitatif, puisque l'on mesure l'échelle pour laquelle il y a un maximum de similarité entre l'opérateur de détection de caractéristiques et la structure locale de l'image. La taille de la région est donc sélectionnée en chaque point et cela indépendamment de la résolution de l'image. L'opérateur Laplacien est utilisé au cours du processus de sélection d'échelle aussi bien pour le détecteur Harris-Affine que pour le détecteur Hessien-Affine. L'opérateur Laplacien a été retenu de manière empirique après une comparaison expérimentale [Mikolajczyk, K. & al : 2001].

Enfin l'estimation de la forme du voisinage est obtenue par le processus itératif suivant : partant d'un ensemble de points initiaux extraits à leur échelle caractéristique, on applique l'estimation itérative des régions elliptiques proposée par Linderberg [Lindeberg, T. 1997]. Les valeurs propres de la matrice des moments du second ordre sont utilisées pour mesurer la forme affine dans le voisinage d'un point. Pour déterminer cette forme affine, il faut trouver la transformation qui projette une structure affine en une autre tout en conservant une matrice ayant les mêmes valeurs propres. Cette transformation est donnée par la racine carrée de la matrice des moments du second ordre : $M^{1/2}$. Soient $X_R = (x_R, y_R)^T$ un point de l'image de droite et $X_L = (x_L, y_L)^T$ le point correspondant dans l'image de gauche, si les voisinages des point X_R et X_L sont normalisés par les transformations $X'_R = M_R^{-1/2} X_R$ et $X'_L = M_L^{-1/2} X_L$, les régions normalisées sont reliées par une simple rotation $X'_L = R X'_R$. Les matrices des moments du second ordre M'_R et M'_L , calculées dans une fenêtre normalisée, sont alors équivalentes à une matrice de rotation (figure 2).




Figure 5 : Illustration de la normalisation affine

Il faut noter que la rotation préserve le rapport des valeurs propres au sein d'une imagerie (région centrée sur un point d'intérêt). La déformation est déterminée à un facteur de rotation près. Ce facteur peut être déterminé par d'autres méthodes comme par exemple des normalisations basées sur l'orientation dominante du gradient [Lowe, D. 1999 ; Mikolajczyk, K. & al : 2002].

L'estimation des régions affines peut être appliquée en tous points initiaux pour lesquels le déterminant de la matrice des moments du second ordre est nettement supérieur à zéro. On peut utiliser cette technique pour estimer la forme des régions initiales formées autour des points d'intérêt données par les détecteurs de Harris et l'interprétation de la matrice du Hessien.

En résumé, les grandes phases de l'algorithme itératif de détection des régions sont :

- 1- Détection des régions initiales avec le détecteur de Harris et le détecteur basé sur le Hessien et sélection de l'échelle,
- 2- Estimation de la forme avec la matrice des moments du second ordre,
- 3- Normalisation des régions affines,
- 4- Aller à l'étape 2 pour un nouveau point initial si les valeurs propres de la matrice des moments du second ordre ne sont pas conservées par la normalisation.

Les détecteurs « Hessien-Affine » et « Harris-affine » présentent l'avantage de détecter un grand nombre de points d'intérêt et augmentent la probabilité d'obtenir un nombre de correspondances correctes important dans les applications utilisant la mise en correspondances comme la reconnaissance et

la détection d'objets [Mikolajczyk, K. & al : 2003] ou encore l'estimation d'homographie et de géométrie épipolaire [Moreels, P. & al : 2007].

1.3.3. EBR

Tuytelaars et Van Gool ont proposé [Tuytelaars, T. & al : 1999] en 1999 un détecteur de régions invariantes aux transformations affines, désigné par l'acronyme EBR pour Edge Based Region. Cette méthode est basée sur la détection de coins de Harris [Harris, C. & al : 1988] et sur les contours de l'image. Ces deux types d'information possèdent la particularité d'être détectables quels que soient les changements d'échelle, de point de vue et d'éclairage. Soit p un point à l'intersection d'un point d'intérêt de Harris et d'un contour obtenu à l'aide du détecteur de contours de Canny-Deriche [Canny, J. 1986]. Soient p_1 et p_2 deux points se déplaçant en sens opposé de part et d'autre de p (voir Figure 6). On définit l_i la vitesse des points par l'équation suivante :

$$l_i = \int abs(|p_i^{(1)}(s_i) - p - p_i(s_i)|) ds_i \quad (2.8)$$

Avec s_i un paramètre de courbure arbitraire, $p_i^{(1)}$ la dérivée première de $p_i(s_i)$, $abs(\cdot)$ représente la valeur absolue et $||$ le déterminant. Cette égalité stipule que l'aire contenue entre le segment $[p_1, p]$ et le contour d'une part, et l'aire entre le segment $[p_2, p]$ et le contour d'autre part, reste identique. Pour plus de simplicité, nous utiliserons l pour se référer à $l_1 = l_2$.

Pour toutes valeurs de l , on définit à partir des points $p_1(l)$, $p_2(l)$ et $p(l)$, un parallélogramme $\Omega(l)$, construit à partir des vecteurs $p_1(l) - p(l)$ et $p_2(l) - p(l)$. Enfin ne seront sélectionnées comme régions d'intérêt que les parallélogrammes donnant des extrema à une fonction monodimensionnelle contenant des attributs de textures. Ces attributs sont définis de la manière suivante :

$$Inv_1 = abs \left(\frac{|p_1 - p_g \quad p_2 - p_g|}{|p - p_1 \quad p - p_2|} \right) \frac{\xi_{00}^1}{\sqrt{\xi_{00}^2 \xi_{00}^0 - (\xi_{00}^1)^2}} \quad (2.9)$$

$$Inv_2 = abs \left(\frac{|p - p_g \quad q - p_g|}{|p - p_1 \quad p - p_2|} \right) \frac{M_{00}^1}{\sqrt{M_{00}^2 M_{00}^0 - (M_{00}^1)^2}} \quad (2.10)$$

avec

$$\xi_{pq}^n = \int_{\Omega} I^n(x, y) x^p y^q dx dy \quad (2.11)$$

et

$$p_g = \left(\frac{\xi_{10}^1}{\xi_{00}^1}, \frac{\xi_{01}^1}{\xi_{00}^1} \right) \quad (2.12)$$

Où ξ_{pq}^n est le moment d'ordre n et de degré $p + q$ calculé dans la région $\Omega(l)$. p_g est le centre de gravité pondéré par l'intensité moyenne de $I(x, y)$. q est un sommet du parallélogramme situé à l'opposé de p .

La principale limite de cette méthode de détection de régions d'intérêts est qu'elle est dépendante des performances du détecteur de Harris et du détecteur de contours utilisé. EBR a été essentiellement utilisé dans les applications de reconnaissance de formes [Tuytelaars, T. & al : 1999].




Figure 6 Exemple de construction d'une région d'intérêt de type EBR

1.3.4. IBR

D'une manière générale, on peut dire qu'IBR (Intensity Based Region) est une méthode de détection de régions d'intérêts qui utilise comme point d'ancrage un extremum de l'intensité de l'image. A partir de ce point d'ancrage, on parcourt l'image à l'aide de rayons tracés autour de ce point.




Figure 7 Illustration de la méthode d'exploration de IBR

Le principe d'exploration est le suivant : partant d'un extremum d'intensité de l'image, on construit la fonction d'intensité définie par les valeurs contenues sur les rayons du cercle centré sur l'extremum local détecté (Figure 7). Outre cette fonction d'intensité, on calcule en tous points du rayon la fonction suivante :

$$f_I(t) = \frac{\text{abs}(I(t) - I_0)}{\max(K, d)} \quad (2.13)$$

$$\text{avec } K = \frac{\int_0^t \text{abs}(I(t) - I_0)}{t}$$

Avec t un paramètre arbitraire le long du rayon, $I(t)$ l'intensité de l'image à la position t , I_0 l'intensité au point d'ancrage et $d > 0$ pour. Les points pour lesquels cette fonction atteint un extremum sont invariants aux transformations affines et aux transformations photométriques.

Enfin pour construire la région finale, on joint les extrema de toutes les fonctions dans l'espace de l'image.

Comme pour EBR, IBR est dépendante des points d'ancrage donc de la robustesse de la méthode de détection de ces points. Les régions d'intérêts localisées par IBR ont notamment été utilisées dans les approches de type « wide baseline matching » [Tuytelaars, T. & al : 2004].

1.3.5. MSER

Matas a présenté en 2002 un détecteur de régions d'intérêts basé sur un algorithme « multi-seuillage » [Matas, J. & al : 2002]. La détection de régions se déroule en deux phases. La première consiste à rechercher des régions

extremums (« extremal région »), la deuxième à sélectionner les régions les plus stables (« Maximally Stable ») parmi l'ensemble des régions détectées pendant la première phase.

Les régions d'extremum sont définies par la propriété suivante : toutes les valeurs des pixels contenus à l'intérieur d'une de ces régions sont inférieures aux valeurs des pixels formant le contour de la région. Ces régions extremums, c'est-à-dire l'ensemble des pixels connectés suite à un seuillage, possèdent un certain nombre de propriétés :

- Une transformation monotone de l'intensité des pixels de l'image ne modifie pas ε , ensemble de toutes les régions extremums de l'image. En effet la constitution de ε ne dépend que de l'ordre des pixels et non de l'intensité. Cela assure donc que les changements photométriques ne modifieront pas les performances de la détection,
- Les transformations géométriques continues préservant la topologie, ceci implique que des pixels connexes dans une région le seront aussi dans la région transformée.

Ces deux propriétés permettent donc l'invariance des régions d'extremum aux transformations géométriques et photométriques.

L'implantation est constituée des phases de détection suivantes: dans un premier temps, on procède à un dénombrement des régions d'extremum. Pour cela on classe les pixels par valeur d'intensité. Les pixels classés sont marqués et une liste de croissance et de fusion contenant tous les pixels connexes est construite et mise à jour à l'aide de l'algorithme « union-find » [Sedgewick, R. 1988]. Pendant la phase de dénombrement, l'image est seuillée, et la surface de chaque ensemble connexe de pixels est évaluée. Les régions les plus stables sont celles pour lesquels la fonction de changements relatifs de surface, en fonction du seuil, est minimum. En d'autres termes, les MSERs sont des parties de l'image où un seuillage local de l'image est stable pour une large plage de seuils.

Les MSERs sont des régions d'intérêts robustes qui ont toutefois pour principal défaut d'être sensibles au flou, ce fait baisser leur capacité de répétabilité [Mikolajczyk, K. & al : 2005b]. Les champs d'applications des MSERs sont surtout la reconnaissance de formes et l'estimation de la géométrie épipolaire [Chum, O. & al : 2006 ; Matas, J. & al : 2002 ; Matas, J. & al : 2004].

1.3.6. PCBRD

Deng introduit en 2007 [Deng, H. & al : 2007], un détecteur de régions basé d'abord sur la détection de zones à forte courbure, puis sur l'algorithme de détection de la ligne de partage des eaux suivi d'une sélection des régions les plus stables sur un grand nombre d'échelles. Le détecteur est constitué de 3 étapes :

Dans un premier temps on procède au calcul des principales zones de courbures de l'image en utilisant la matrice du Hessien. Le but de cette étape est d'extraire de longues structures comme les lignes (lignes droites ou lignes généralisées) et les contours.

$$H = \begin{bmatrix} I_{xx}(x, y, \sigma_D) & I_{xy}(x, y, \sigma_D) \\ I_{xy}(x, y, \sigma_D) & I_{yy}(x, y, \sigma_D) \end{bmatrix} \quad (2.14)$$

Cependant comme nous l'avons expliqué plus haut dans la description du détecteur Hessien-Affine, on ne peut pas utiliser directement le déterminant de la matrice du Hessien car il pénalise trop les très grandes structures. C'est pour cette raison que l'auteur propose de créer une image des courbures principales en utilisant les opérateurs suivants :

$$P(x, y) = \max(\lambda_1(x, y), 0) \quad (2.15)$$

$$P(x, y) = \min(\lambda_2(x, y), 0) \quad (2.16)$$

où $\lambda_1(x, y)$ et $\lambda_2(x, y)$ sont respectivement le maximum et le minimum des valeurs propres de H au point de coordonnées (x, y) . L'équation (2.15) fournit une réponse pour les structures foncées sur fond clair (ou les parties sombres des contours d'une forme) et l'équation (2.16) fournit quant à elle une information sur les formes claires détectés sur un fond sombre.

De plus, la phase de création de l'image des courbures principales est, comme le détecteur de Lowe [Lowe, D. 1999] et bon nombre d'autres, calculés dans un espace d'échelle. Dans un premier temps, la taille de l'image originale voit sa taille doublée pour créer l'image initiale I_{11} . Ensuite, on crée un ensemble d'images I_{1j} lissées par un noyau gaussien dont l'écart-type est défini de la façon suivante :

$$\sigma = k^{j-1} \quad (2.17)$$

où $k = 2^{1/3}$

et $j = \{1 \dots 6\}$

La première octave consiste en une liste de six images, I_{11} à I_{16} . La première image de la seconde octave est obtenue par une division par deux de la taille de l'image I_{14} . Le même processus de lissage est appliqué pour créer la seconde octave. Ce système produit un ensemble total de $n = \ln(\min(w, h)) - 3$ octaves où w et h , sont respectivement la largeur et la hauteur de l'image. Enfin on calcule l'image des principales courbures, notée P_{ij} , pour chaque image lissée en utilisant le maximum des valeurs propres (eq: (2.15)) de la matrice du Hessien et chaque point d'image (ou respectivement le minimum (eq: (2.16))).




Figure 8 : Illustration des résultats de PCBRD. (a) image originale. (b) Image des courbures principales. (c) Images des courbures principales « nettoyées ». (d) Régions issues de l'algorithme de lignes de partages des eaux et (e) régions finales

A partir de toutes les images des principales courbures P_{IJ} , on calcule le maximum pour trois images consécutives au sein d'une même octave. Ceci forme un ensemble de quatre images pour chacune des n octaves.

Après avoir créé les images des courbures principales, il est nécessaire de déterminer les régions d'intérêt. Ces régions sont obtenues en appliquant un algorithme de « ligne de partage des eaux ». Cet algorithme couramment utilisé en segmentation d'images est en général appliqué sur une image ou sur les valeurs du gradient de l'image. Dans le cas du PCBRD, l'algorithme de « ligne de partage des eaux » est appliqué sur les images des courbures principales. Cependant, un prétraitement doit être appliqué pour réaliser un « nettoyage » de l'image en utilisant l'opération de morphologie mathématique : « ouverture » dans le but de retirer une partie du bruit qui pourrait rendre instable l'algorithme de ligne de partage des eaux. Le résultat fourni par cet algorithme est un ensemble de régions formées par les bassins de part et d'autre des lignes de partages des eaux.

Enfin les régions les plus stables au sein de l'espace d'échelle sont sélectionnées. Les régions retenues sont celles qui, d'une part, sont détectées

à 3 niveaux d'échelle consécutifs et d'autre part, dont le recouvrement, au sens de la définition donnée par [Mikolajczyk, K. & al : 2005b], est d'au moins 70%. Cette valeur a été validée expérimentalement par l'auteur dans [Deng, H. & al : 2007].

Les applications de ce détecteur sont la reconnaissance de formes et la détection de la symétrie [Deng, H. & al : 2007].

1.4. Méthodes de reconnaissance de formes utilisant les contours pour obtenir des régions d'intérêt

Les méthodes introduites ci-dessus, permettent de détecter des points ou des régions d'intérêts de manière stable. Ces détecteurs sont capables de localiser des régions d'intérêts autour de structures apparaissant comme des coins ou comme des « bulles » (blobs). Plus accidentellement, ils peuvent détecter des points localisés sur des contours d'une longueur importante. En effet, ces méthodes de détection pénalisent fortement les structures allongées [Mikolajczyk, K. & al : 2003]. Cette limite a motivé les travaux de certains auteurs qui utilisent les points de contour pour détecter les régions d'intérêts.

En 2003, Mikolajczyk a présenté une méthode de reconnaissance de formes basée sur la mise en correspondance de régions d'intérêt obtenues à partir de contours. La démarche retenue par l'auteur pour obtenir ces régions est la suivante. Dans un premier temps, les contours sont extraits en utilisant une version multi-échelle du détecteur de Canny [Canny, J. 1986]. Ensuite chaque point de contour est utilisé pour créer une région d'intérêt dans le voisinage du point d'étude. Ce voisinage est un cercle centré sur un point de contour et de rayon σ . Le paramètre σ est déterminé en utilisant une sélection d'échelle caractéristique. Cette sélection est obtenue en cherchant l'échelle σ pour laquelle la réponse de l'opérateur laplacien atteint un extremum. Enfin la dernière étape de la détermination de la région d'intérêt est la séparation en deux parties du cercle obtenu précédemment. Une partie contiendra des informations relatives au fond, l'autre contiendra les informations relatives à l'objet. En effet, il est nécessaire de séparer le l'objet du fond afin que la mise en correspondance future soit invariante au changement de fond. Cette séparation est réalisée en estimant la droite représentant au mieux le contour. Cette estimation est effectuée en utilisant la méthode RANSAC.

Pour caractériser les régions obtenues, l'auteur propose une variante de SIFT. Le descripteur proposé est formé par deux histogrammes. Le premier histogramme représente la distribution de l'orientation du gradient des points de contours. L'orientation du gradient est estimée selon 4 orientations dans une grille d'échantillonnage 2x2. La dimension du premier vecteur descripteur est donc 16. Le second histogramme, représente aussi l'orientation du gradient des points de contour. Cette fois-ci, l'histogramme est obtenu avec une grille d'échantillonnage 4x4 et selon 8 orientations. La dimension de ce descripteur est donc 128.

La mise en correspondance est effectuée en deux étapes. La première étape permet la recherche de correspondances en étudiant la similarité des histogrammes et la cohérence géométrique des candidats voisins.

Pendant la première phase, pour chaque paire de descripteurs (l'un provenant du modèle de l'objet, l'autre provenant de l'image en cours de test), on calcule deux distances. La première distance est obtenue à partir de la distance euclidienne calculée en utilisant l'histogramme à 16 dimensions. La seconde distance est obtenue en calculant un score prenant en compte la distance entre descripteurs et la cohérence géométrique du voisinage. Ce score est calculé en utilisant l'histogramme de dimension 128 et uniquement sur les paires de points ayant la distance minimum lors du premier calcul de distance.

La deuxième phase de la mise en correspondance permet d'obtenir la détection et le positionnement de l'objet, en utilisant un système de vote dans l'espace de Hough représentant un modèle de transformation affine à l'aide des meilleures paires obtenues précédemment.

L'auteur a validé son approche sur deux objets que l'on peut considérer comme localement plans : les vélos et les raquettes. Des exemples de détections et localisations sont présentés à la Figure 1.

Un des principaux avantages de la méthode est qu'une seule image est nécessaire pour obtenir le modèle de l'objet à reconnaître. Cependant les temps de calcul importants de cette méthode en sont la principale limite.

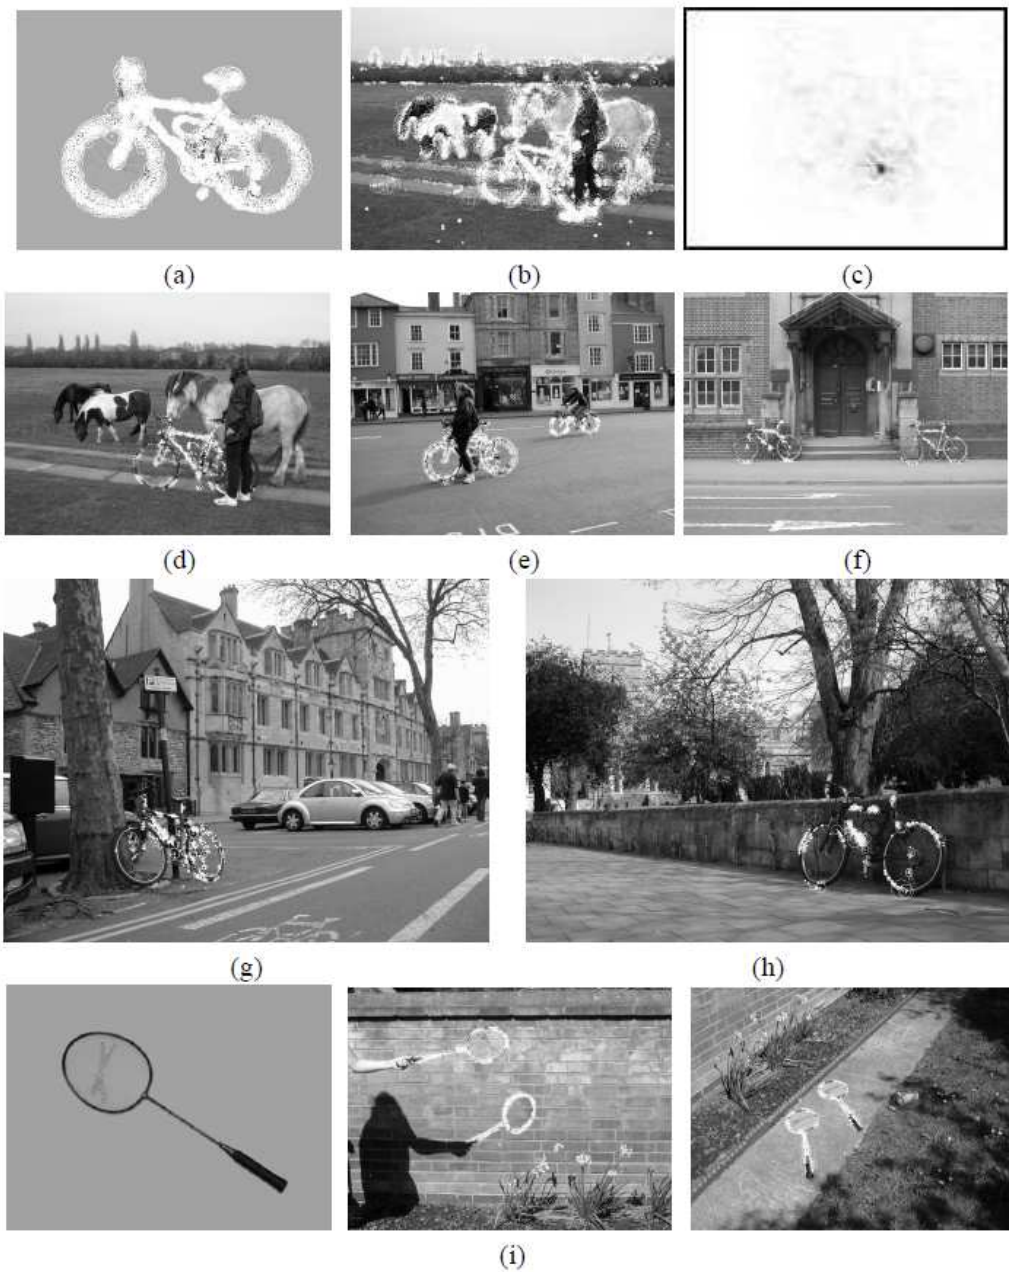


Figure 9 : Exemple de résultats obtenus par la méthode de K. Mikolajczyk

Une seconde approche assez différente est présentée par Carmichael [Carmichael, O. & al : 2004]. Cette méthode consiste à réaliser la détection à

l'aide d'une cascade de classifieurs. Cette cascade est obtenue en réalisant un apprentissage sur des images où les objets à reconnaître sont séparés du fond. Les caractéristiques à l'entrée du classifieur sont la densité des points de contours dans le voisinage d'un point de contour donné. Cette quantité, appelée « *edge probe* », est définie par :

$$ep(p, G) = \sum_{t \in G} e^{\left(-\frac{\|p-t\|^2}{\sigma^2} \right)} \quad (2.18)$$

Où p sont les coordonnées du point de contour central d'un voisinage de taille δ . G est une liste de points de contour contenu dans le voisinage. t est un vecteur contenant les coordonnées des points de contour au sein du voisinage. σ est un arbitraire défini par l'utilisateur. Cette façon de décrire les contours est très proche du Shape Context proposé par Belongie [Belongie, S. & al : 2002], que nous verrons plus précisément dans le chapitre 4 de ce mémoire.

Le classifieur final est construit en cascasant plusieurs niveaux de classifieurs spécifiques. Chaque niveau contient des classifieurs qui ont été entraînés avec une taille de voisinage d'étude particulière. Plus le niveau du classifieur est élevé, plus la taille du voisinage, pour lequel les caractéristiques d'apprentissage ont été obtenues, est grand.

Une fonction d'agrégation permet la localisation de l'objet dans au sein d'un rectangle englobant.

L'étude des performances et de la sensibilité des paramètres a été évaluées sur une base d'images composés par l'auteur nommé WORD¹ (Wiry Object Recognition Database).

Des exemples de détections sont présentés à la Figure 10. Les images de la première colonne représentent tous les contours de l'image. La seconde colonne représente les points de contours appartenant à l'objet « escabeau ». La troisième colonne représente la localisation de l'objet détecté, sous forme de rectangle englobant.

Le principal avantage de cette méthode est le temps d'analyse d'une image relativement faible (4 sec [Carmichael, O. & al : 2004]) pour une image de résolution 1600x1200. La contrainte principale de cette méthode est le nombre important d'images nécessaires pour réaliser la cascade de classifieurs.

¹ <http://rope.ucdavis.edu/~owenc/word/>



Figure 10 : Exemple de résultats de la méthode Carmichael

1.5. Les détecteurs de lignes généralisées et de régions curvilinéaires

Les méthodes présentées ci-dessus (exceptées celles de Mikolajczyk et de Carmichael) permettent de représenter les régions détectées comme des rectangles englobant ou des ellipses englobantes. Cependant un grand nombre d'objets ou parties d'objets sont très mal séparés du fond par les opérateurs locaux standards. C'est le cas des vélos, portails ou encore les câbles visibles à la Figure 11. Dans la plupart des cas, les régions détectées contiendraient un grand nombre de pixels appartenant au fond. Ces objets étant constitués en grande partie de segments en forme de tubulure, il apparaît judicieux de décrire les objets à partir de ces formes appelées régions curvilinéaires. Nous allons décrire dans la section suivante les différentes méthodes existantes permettant la détection de ces régions caractéristiques.



Figure 11 : Exemple d'objet mal décrits par les détecteurs locaux standards. (ici un Hessien-Affine)

1.5.1. Méthodes basées sur des critères purement locaux

Cette première famille d'approche permet l'extraction de structures curvilinéaires en considérant uniquement les niveaux de gris de l'image et en utilisant des critères purement locaux comme par exemple des différences locales de niveaux de gris. Un des problèmes de ce type d'approche est le nombre important de faux positifs² générés, car, bien souvent, de nombreux points respectent les critères de détection. Il est donc nécessaire de mettre en place des heuristiques [Fischler, M. A. 1981 ; Montesinos, P. & al : 1996] nécessitant des charges de calculs importantes pour filtrer ces fausses alarmes. Nous allons détailler ci-dessous quelques méthodes de détection de lignes basées sur les critères locaux.

Dans [Fischler, M. A. & al : 1983], l'extraction des régions curvilinéaires débute par un lissage de l'image puis une recherche des maxima locaux sur les lignes puis sur les colonnes de l'image. Les maxima locaux sont les points pour lesquels la valeur de niveau de gris est plus grande que celle de ses voisins les plus proches. A partir de ces maxima, on calcule deux attributs :

- la différence entre les minima de part et d'autre du maximum détecté,
- la valeur moyenne des niveaux de gris entre les minima placés de part et d'autre du maximum détecté.

A partir de ces attributs, les lignes de saillance ou lignes de crêtes des régions curvilinéaires sont déterminées en réalisant un seuillage sur ces attributs. Les

² zone de l'image classée comme appartenant à une forme curvilinéaire alors qu'elle n'appartient pas à l'une de ces formes.

seuils sont déterminés de manière individuelle pour chaque image. Le principal défaut de cette méthode est le nombre important de faux positifs qu'elle provoque [Steger, C. 1998b].

Une méthode d'extraction plus complexe est décrite dans [Fischler, M. A. & al : 1981b]. Dans ce cas, les résultats donnés par plusieurs opérateurs basés sur l'exploitation des niveaux de gris, sont combinés au sein d'une fonction de coût. Ces opérateurs sont divisés en deux groupes.

Le premier contient des opérateurs évolués, donnant peu de faux positifs pour des lignes ayant de faibles probabilités, comme l'opérateur de détection de route de Duda, ce qui peut entraîner à briser certaines lignes.

Le second groupe est celui des opérateurs de plus bas niveau, qui retournent une réponse importante pour les routes mais aussi un nombre important de faux positifs. On peut inclure dans ce groupe tous les détecteurs de contours comme Prewitt, Sobel...

A partir des opérateurs du premier groupe, on extrait les candidats pouvant appartenir à une ligne, en réalisant un seuillage ainsi qu'une minimisation d'un chemin dans un graphe de type «spanning tree» entre les différents candidats. Une approche très similaire est présentée dans [Dobie, M. R. & al : 1994]. L'unique différence réside dans le fait que le type d'opérateur utilisé dans ce cas appartient au second groupe.

Une approche complètement différente est décrite dans [Lacroix, V. & al : 1996]. Ici les lignes sont détectées en calculant le gradient dans un voisinage 4x4. Les valeurs du gradient sont obtenues par convolution de l'image avec une fonction à noyau Gaussien. Après cette première étape les contours des formes curvilinéaires apparaissent sous forme de maxima locaux. Afin de détecter les lignes proprement dites, un algorithme d'appariement des points de contour est utilisé. Cet algorithme consiste à rechercher, à partir d'un maximum local, un autre maximum local ayant un gradient de direction opposée. La recherche est effectuée dans le sens opposé à direction du gradient au point initial. Les problèmes principaux de cette méthode sont d'une part le nombre important de candidats potentiels et d'autre part le fait que les structures comme les coins et les cercles, par exemple, répondent parfaitement à ces contraintes, et généreront donc de nombreux faux positifs.

1.5.2. Méthodes d'extraction utilisant la géométrie des régions curvilinéaires

D'une manière générale, les auteurs utilisant ces méthodes considèrent les images comme des fonctions $f: \mathbb{R}^n \rightarrow \mathbb{R}$. La plupart du temps, on suppose que $n=2$, dans un but de simplification de la représentation. Avec cette représentation des images, les régions curvilinéaires apparaissent comme des crêtes et des ravins dans f . Bien souvent les algorithmes présentés dans la littérature permettent d'extraire les crêtes. Pour extraire les ravins, il suffit de considérer le négatif de l'image, soit la fonction $-f$. Il existe différentes manières de définir une crête. Un état de l'art complet a été mené dans [Koenderink, J. J. & al : 1994]. La manière de définir ces crêtes de façon la plus intuitive et par analogie avec le relief terrestre, consiste les voir comme la ligne de partage des eaux.

Une classification des différentes façons de définir et détecter les crêtes est faite par Eberly dans [Eberly, D. & al : 1993]. On peut les classer en quatre familles :

- Les méthodes d'extraction à partir du maximum de courbures des profils des enveloppes des crêtes
- Les méthodes d'extraction à partir des maxima de courbure de l'image
- Les méthodes d'extraction à partir d'un ensemble restreint des maxima de l'image

1.5.2.1. *Les méthodes d'extraction à partir du maximum de courbures des profils des enveloppes des crêtes*

Une manière de définir une crête est la suivante : considérant l'image comme étant l'équivalent d'un terrain en 3 dimensions, les crêtes sont composées des points pris sur les lignes de niveau (isophotes) pour laquelle la courbure de ces lignes atteint des maxima locaux. Cette définition peut s'avérer inutilisable dans certains cas, comme par exemple pour les objets parfaitement rectilignes ou circulaires et d'intensité uniforme, pour lesquels les lignes de niveau ne présenteront pas de maximum de courbure. Il sera alors impossible de définir les crêtes. C'est aussi le cas pour les objets présentant des lignes de courbures très accidentées, c'est-à-dire provenant d'images texturées ou bruitées. Dans ces cas la détection des crêtes se révèle très imprécises (des exemples de mauvaises détections sont données dans [Koenderink, J. J. & al : 1994] et [Maintz, J. B. A. & al : 1996]).

Une approche utilisant directement cette technique est présentée dans [Kweon, I. S. & al : 1994], l'auteur propose dans un premier temps d'extraire les lignes de niveau en utilisant un algorithme multi-seuillage. Puis un « arbre des changements topographiques » (topographic change tree) est créé à partir de ces lignes. Enfin les maxima de courbures sont extraits de l'arbre en calculant les positions des pics et des creux stockés dans l'arbre.

Une approche utilisée par les auteurs dans [Gauch, J. M. & al : 1993 ; Koenderink, J. J. & al : 1994 ; Maintz, J. B. A. & al : 1996] consiste à utiliser une définition explicite de la courbure et de sa direction pour trouver les maxima locaux. A partir d'un maximum local, d'autres maxima sont recherchés dans la direction opposée. Dans ces travaux les auteurs ont utilisé la définition suivante de la courbure :

$$K = -\frac{I_x^2 I_{yy} + I_y^2 I_{xx} - 2I_x I_y I_{xy}}{(I_x^2 + I_y^2)^{3/2}} \quad (2.19)$$

où I_x, I_y, I_{xx}, I_{yy} et I_{xy} sont les dérivées du premier et du second ordre de l'image.

Une approche intéressante, permettant d'augmenter la précision de la détection, est donnée dans [Gauch, J. M. & al : 1993]. Les crêtes extraites sont mises en correspondance avec les contours provenant de l'algorithme de lignes de partage des eaux et ce à plusieurs échelles.

1.5.2.2. *Crêtes détectées en utilisant les maxima de courbures de l'image*

Considérant la surface formée par l'intensité de l'image f , un certain nombre de méthodes [Koenderink, J. J. 1990] [Tran, H & al : 2005] [Porteous, I. R. 1994] d'extraction consistent à chercher les points où l'image présente à la fois un extremum de l'intensité et un extremum de la valeur de la courbure. Comme dans l'approche précédente, cette définition est insuffisante pour pouvoir détecter des lignes au profil plat ainsi qu'au profil très bruité.

Une approche utilisant cette définition pour la détection de crêtes est décrites dans [Monga, O. & al : 1995]. Comme la courbure dépend de la dérivée seconde de l'image et de ces maxima locaux, l'algorithme débute par la convolution avec des noyaux de dérivées de gaussiennes. A partir du résultat de la convolution on détermine les maxima locaux de la courbure ainsi que les directions de cette courbure. Cette méthode pose deux problèmes principaux. Le premier est que cette méthode détecte à la fois les crêtes mais

aussi les contours. Le second problème rencontré est le fait que, suivant la taille des noyaux gaussiens utilisés, les crêtes de très petites largeurs ne seront pas détectées. Une extension multi-échelle de cet algorithme a été proposée par les auteurs dans [Armande, N. & al : 1997] pour palier à ce problème.

1.5.2.3. *Détection des lignes à partir d'un sous ensemble de maxima locaux de l'image*

Une autre approche pour définir une crête est basée sur l'observation suivante : si quelqu'un se déplace le long d'une crête, le terrain est descendant de part et d'autre du chemin emprunté. Ceci veut dire qu'il existe un maximum d'altitude (de niveau de gris dans le cas d'une image) perpendiculairement à la direction de la crête. Cette direction peut être obtenue de la manière suivante : comme le terrain descend des deux cotés de la crête, la dérivée seconde du signal pris perpendiculairement à la direction de la crête a une valeur négative très importante [Eberly, D. & al : 1993]. Par conséquent la direction de la perpendiculaire à la crête est donnée par le vecteur propre de la matrice du Hessian de $f(x, y)$ ayant la plus petite valeur propre.

Plusieurs auteurs [Haralick, R. M. 1983 ; Wang, L. & al : 1993a ; Wang, L. & al : 1993b] utilisent cette définition en association à un modèle de maillage 3D à facette pour détecter les bords des crêtes.

1.5.3. Méthodes d'extraction utilisant les méthodes de filtrage

Outre les méthodes de détections basées sur les critères de détections utilisant les niveaux de gris et les méthodes basées sur la détection de lignes généralisées vu comme des lignes de crêtes, de nombreuses méthodes utilisant des techniques de filtres sont disponibles dans la littérature. La plupart de ces approches utilisent, pour la détection des régions curvilinéaires, la combinaison des résultats de filtres linéaires (principalement des filtres gaussiens) et des filtres sont linéaires.

La méthode proposée par [Iverson, L. A. & al : 1995] repose sur l'observation suivante : la plupart des filtres linéaires permettent de détecter les caractéristiques pour lesquelles ils ont été conçus mais aussi d'autres caractéristiques non pertinentes. Ainsi, la convolution d'une image avec la dérivée seconde d'un noyau gaussien donne des réponses importantes sur les

lignes mais aussi sur les contours. Idéalement, ce genre d'approche devrait donner une réponse nulle sur les caractéristiques non pertinentes. Les auteurs argumentent du fait que pour parer à ce problème une combinaison non-linéaire de filtres linéaires est nécessaire et donne de meilleurs résultats [Iverson, L. A. & al : 1995]. Ils proposent donc pour cela un système booléen alimenté par les valeurs de filtres linéaires. Ils décrivent les conditions nécessaires pour obtenir une ligne idéale. Ces conditions utilisées sont proches de celles utilisées pour le détecteur de crêtes, c'est-à-dire qu'une structure curvilinéaire doit présenter un maximum local sur une perpendiculaire à la direction donnée par la structure. L'aspect le plus important de cette technique réside dans le fait qu'on peut suivre la ligne du début à la fin. De plus cette méthode permet de détecter les lignes même en cas de présence de jonctions, comme dans le cas d'un croisement routier par exemple. Cependant les temps de calculs de cette méthode s'avèrent très élevés.

La méthode présentée dans [Gerig, G. & al : 1990] met en valeur les structures curvilineaires en utilisant un simple seuillage, puis utilise une convolution du résultat avec la dérivée seconde d'une fonction gaussienne. Cependant cette dérivée seconde répond sur les contours placés de part et d'autre des régions curvilinéaires. Ces fausses détections non désirables peuvent être supprimées en utilisant une diffusion anisotropique [Weickert, J. 1998]. Malheureusement l'ensemble des fausses détections ne sont pas complètement supprimées par l'utilisation de cette technique. De plus le choix de la valeur du seuil initial apparaît aussi comme un problème important.

Une approche assez similaire est détaillée dans [Press, W. H. & al : 1992]. Encore une fois les lignes sont mises en valeur en utilisant une technique de seuillage. La direction de la ligne et la valeur de la réponse sont obtenues à partir de la matrice du Hessien calculée sur l'image originale lissée par une gaussienne. Cette méthode est assez similaire à la méthode présentée à la section 1.5.2.3, bien que n'utilisant pas la dérivée première. La dernière étape de cette technique consiste à supprimer les structures non désirables en analysant la continuité de la direction des structures détectées. Ceci permet de supprimer les structures de type « bulle » ou bien de formes elliptiques. Enfin on peut noter que pour pouvoir détecter différentes largeurs de lignes et notamment les plus fines, une stratégie multi-échelle est adoptée.

La technique introduite par [Koller, T. M. & al : 1994 ; Koller, T. M. & al : 1995] est basée sur le principe qu'une structure curvilinéaire doit avoir de part et d'autre un contour. Pour détecter ces contours l'auteur utilise deux filtres utilisant chacun une dérivée première d'une fonction gaussienne de signes opposés. Une combinaison non-linéaire des résultats des filtres a été créée pour obtenir une réponse unique qui est maximum lorsque l'on obtient deux contours de signes opposés. Cette approche nécessite deux paramètres importants. Le premier paramètre est l'écart type de la gaussienne qui doit être choisit proportionnellement à la largeur de la ligne. L'auteur détermine empiriquement que cette valeur doit être égale à la moitié de la largeur de la ligne. Le second paramètre important est le sens de la direction d'application des filtres dans l'image. Cette direction est obtenue en utilisant les vecteurs propres de la matrice du Hessien. Le problème principal de cette méthode est le temps de calcul important car on doit répéter l'approche en tout point avec différentes valeurs d'écart types pour détecter des lignes de différentes largeurs.

1.5.4. Méthode utilisant un modèle pour la détection de région curvilinéaire

Nous allons présenter ici les méthodes permettant la détection de régions curvilinéaires à l'aide d'un modèle explicite représentant ces régions. Ces modèles permettent l'estimation de l'axe central de la région et de la largeur de celle-ci en tout point.

L'approche de Linderberg dans [Lindeberg, T. 1996 ; Lindeberg, T. 1998] suppose qu'un profil d'une section perpendiculaire à la direction d'une ligne est assimilable à une fonction gaussienne. La largeur du modèle est modulée par l'écart type de la gaussienne noté σ_0 . Cet algorithme est multi-échelle, c'est-à-dire qu'on utilise plusieurs valeurs de l'écart type. Les points d'une ligne sont détectés à une seule échelle par la technique présentée à la section 1.5.2.3, c'est-à-dire aux endroits où la dérivée première dans la direction des maxima des courbures principales est nulle. La nouveauté de cette approche est la définition d'une mesure normalisée au sein de l'espace d'échelle appelée « γ -normalized ». Cette mesure est définie par :

$$W = R \cdot t^\gamma \quad (2.20)$$

Avec $\gamma = \sigma^2$ où σ l'écart type de la fonction gaussienne utilisée pour obtenir l'échelle en cours.

R est appelé ridgness et est défini par le maximum des dérivées secondes dans la direction x et y .

Le choix de la valeur de γ est important car il influe sur la précision de détection de la largeur des structures curvilinéaires, Le temps de calcul lié à l'implémentation de cette méthode est toutefois très élevé. D'autre part, le biais introduit par le lissage des fonctions gaussiennes pour la détection de la position des lignes diminue son intérêt.

Une approche assez similaire est développée dans [Lorenz, C. & al : 1997a ; Lorenz, C. & al : 1997b]. Ici les auteurs évaluent quatre modèles de profil de lignes :

- Gaussienne
- Porte idéale
- Triangulaire
- Parabolique

Comme précédemment, on calcule la réponse d'un opérateur au sein d'un espace d'échelle de type « γ -normalized ». Cette réponse est donnée par :

$$R = \sigma^\gamma |\lambda_p| |\lambda_l| \quad (2.21)$$

où λ_p est la dérivée seconde perpendiculaire à la direction de la ligne et λ_l la dérivée seconde dans la direction de la ligne. Les auteurs montrent que pour chaque profil de ligne, la valeur optimale pour le paramètre σ déterminé par la réponse de leur détecteur est 0.4 fois la largeur de la ligne. La largeur d'une ligne est déterminée à mi-hauteur des niveaux de gris des contours.

Enfin dans [Steger, C. 1998a ; Steger, C. 1998b], l'auteur propose d'utiliser le modèle de profil de ligne suivant :

$$f_p(x) = \begin{cases} h(1 - (x/w)^2), & |x| < w \\ 0, & |x| > w \end{cases} \quad (2.22)$$

où w est la largeur de la région curvilinéaire.

L'auteur démontre que la position du centre de la région est donnée par les positions des points où la dérivée première est nulle et la dérivée seconde est très négative. Il faut noter que les dérivées sont calculées en convoluant les dérivées premières et secondes de noyaux gaussiens. Steger montre après une étude sur l'influence de l'écart-type des gaussiennes que la valeur $\sigma = 0.3w$ est un bon compromis entre précision de mesure de largeur et taux de faux positifs. De plus pour calculer la largeur du profil de la ligne, c'est-à-dire ses contours, l'auteur retient les points où l'on trouve à la fois un maximum pour la dérivée première et un passage par zéro pour la dérivée seconde.

Après présentation de son modèle de profil de ligne, l'auteur propose de l'étendre en 2D, en l'appliquant perpendiculairement aux structures curvilinéaires. Ces directions sont déterminées comme à la section 1.5.2.3 en interprétant les vecteurs propres et les valeurs propres de la matrice du Hessien. Après cette étape les points candidats sont reliés en utilisant un algorithme d'analyse de connexité. Une des particularités et singularités de ce détecteur réside dans l'algorithme de correction du biais introduit par l'utilisation des filtres gaussiens.

1.5.5. Détecteurs de régions curvilinéaires spécifiquement adaptés à la détection des veines de la rétine

De nombreuses méthodes de détection de formes curvilinéaires ont été plus particulièrement étudiées dans le cadre des images médicales, notamment pour détecter les veines, les bronches, voire les circonvolutions du cerveau. Nous nous sommes ici restreints aux méthodes appliquées à la détection de veines dans les images de la rétine, que nous avons pu comparer à notre détecteur dans le chapitre suivant.

En 2004, Staal [Staal, J. & al : 2004] propose une méthode de détection de veines de la rétine basé sur l'interprétation des dérivés de l'image et la classification.

Dans un premier temps, on calcule en chaque point de l'image et pour une taille de voisinage donnée le scalaire suivant :

$$\rho(X, \sigma) = -\frac{1}{2} \text{sign}(\lambda) \left| \text{sign} \left(\nabla I \left(X + \varepsilon \hat{v}, \sigma \right) \cdot \hat{v} \right) - \text{sign} \left(\nabla I \left(X - \varepsilon \hat{v}, \sigma \right) \cdot \hat{v} \right) \right| \quad (2.23)$$

Où ∇ est l'opérateur gradient, λ est la plus grande valeur propre de la matrice du Hessien H , \hat{v} est le vecteur propre de la matrice du Hessien correspondant à la plus grande valeur propre λ .

Ce scalaire peut être estimé en tous points de l'image à l'échelle σ . Cette valeur vaudra -1 si un ravin est détecté, 1 si une crête est détectée et 0 partout ailleurs. Il permet de détecter des points d'une région curvilinéaire possédant des gradients de signes opposés et dotée d'une forte courbure de la surface de la région curvilinéaire localisée sur la ligne de crête.

Après cette phase de détection des points appartenant aux régions curvilinéaires, une phase de regroupement des points appartenant à la même région est effectuée

Enfin à partir de cette segmentation, un certain nombre de caractéristiques (27) sont extraites pour entraîner un classifieur de type « K plus proches voisins (KPPV) ».

En 1989, Chaudhuri [Chaudhuri, S. & al : 1989] a proposé une méthode de détection de veines de la rétine partant de l'observation qu'une section de la rétine présente un profil que l'on peut approximer par une fonction gaussienne. Un filtre 2D dit « de correspondance » est proposé par l'auteur pour la détection des vaisseaux. Les vaisseaux sont détectés selon différentes orientations en convoluant le filtre dans différentes positions. On retiendra l'orientation pour laquelle la réponse du filtre est maximale. Le résultat du filtre peut être seuillé de manière à obtenir une segmentation binaire de l'image.

En 1999, Martinez-Perez [Martinez-Perez, M. & al : 1999] a proposé une méthode de détection des veines utilisant une combinaison d'une analyse au sein de l'espace d'échelle et d'une méthode de croissance de région. Deux paramètres, calculés à différentes échelles, sont utilisés pour caractériser les vaisseaux sanguins : la norme du gradient de l'image et la courbure de la surface des crêtes. La courbure est déterminée par la plus grande valeur propre de la matrice du Hessien.

Ces deux caractéristiques sont utilisées durant la phase de croissance afin de regrouper les pixels appartenant soit à la classe « fond » soit à la classe « veine ».

Jiang a proposé en 2003 dans [Jiang, X. & al : 2003], une méthode d'extraction des veines basée sur un algorithme de seuillage localement adaptatif. En effet les veines de la rétine ne peuvent être extraites avec un seuillage global. L'auteur propose de sonder l'image avec un certain nombre de seuil. A chaque seuil testé, tous les pixels supérieurs au seuil sont extraits. Les pixels connexes forment des objets. Les objets semblables à des veines sont conservés en utilisant une phase de classification. Tous les objets conservés peuvent être combinée pour former un « arbre binaire de segmentation des veines ». La sensibilité de cette méthode peut être modifiée en faisant varier les paramètres de la procédure de classification.

Ces différentes méthodes ont été comparées de manière systématique sur une base d'images commune dite « DRIVE » (Digital Retinal Images for Vessel Extraction). La courbe ROC présentée dans [Niemeijer, M. & al : 2004] montre que la méthode de Staal donne les meilleurs résultats. Nous présenterons en détail le protocole utilisé et une comparaison avec les résultats de notre détecteur dans le chapitre suivant.

Chapitre 2. Définition d'un détecteur de régions curvilinéaires

2.1. Observations

Ayant parcouru dans le chapitre précédent plusieurs méthodes de détection de formes ou régions curvilinéaires, nous avons souhaité définir notre propre détecteur, reprenant certains points clés des détecteurs existants et en tentant d'apporter nos propres contributions permettant de combler certaines lacunes des méthodes courantes, parfois trop spécialisées pour un problème particulier. Nous souhaitons en effet ici détecter toute sorte de régions, sans nous intéresser aux intersections, et avec un a priori minimum sur la largeur des formes à détecter. Nous souhaitons également que ces régions soient les plus répétables possible au sens des opérations de mise en correspondance, ce qui nous conduira parfois à définir des contraintes qui élimineront des régions trop « bruitées » qui sont parfois détectées avec les opérateurs existants.

Nous présentons donc dans cette section les observations qui nous ont permis de définir les contraintes caractérisant au mieux les régions curvilinéaires que nous souhaitons extraire. Ces observations conduiront à la définition d'un modèle, qui lui-même permettra la définition du détecteur correspondant.

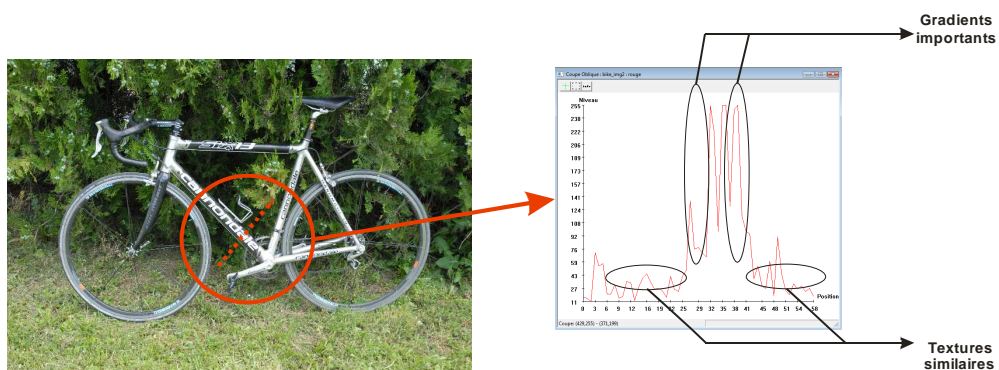


Figure 12 : Observation des propriétés d'une section d'une région

Les observations représentées sur la Figure 12, nous permettent de formuler trois remarques :

- au sein d'une section réalisée perpendiculairement aux contours d'une structure curvilinéaire, une région curvilinéaire possède des gradients de normes importantes et de sens opposés localisés sur les contours

de la structure curvilinéaire. Ce critère a largement été utilisé dans les méthodes présentées dans l'état de l'art [Fischler, M. A. & al : 1983 ; Steger, C. 1998b], notamment au niveau de la détection des veines [Staal, J. & al : 2004].

- les textures bordant la structure curvilinéaire sont très similaires tant au niveau de la luminance moyenne que du spectre fréquentiel. Ce critère n'est pas pris en compte dans les méthodes que nous avons pu étudier, si ce n'est pas le biais d'un lissage gaussien qui ne prend pas vraiment en compte la notion de similarité de textures.
- la partie du signal correspondant à l'information contenue à l'intérieur de la structure curvilinéaire peut présenter des variations fréquentielles importantes. Il faudra donc que notre détecteur ne soit pas sensible à ces variations et ne réalise pas de fausses détections dans cette partie du signal. De même, les détecteurs existants ne prennent en général pas en compte ce problème si ce n'est à travers le lissage gaussien.

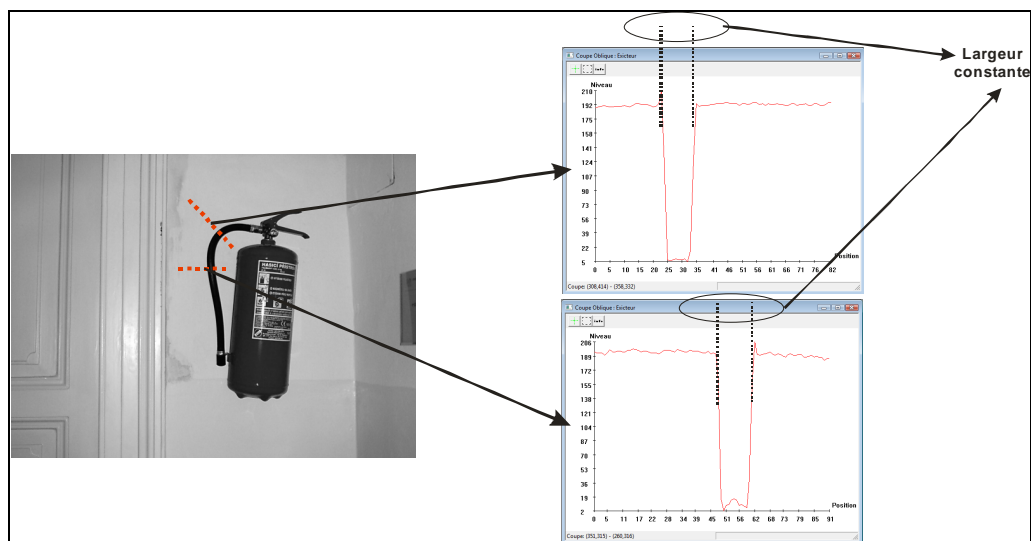


Figure 13 : Illustration de la conservation de la largeur d'une région curvilinéaire sur l'ensemble de sa longueur

La Figure 13 nous permet d'affirmer que la largeur d'une région curvilinéaire (ici le tuyau de l'extincteur) est constante ou quasi-constante sur l'ensemble de sa longueur. Toutefois, il sera nécessaire d'introduire une tolérance sur

cette contrainte afin de prendre en compte la déformation éventuelle due à la perspective. De plus, afin d'éliminer les régions trop bruitées, nous supposons que les variations locales de largeur sont faibles également. Un étranglement ou un élargissement brutal dans une forme curvilinéaire conduira donc à la détecter en deux parties.



Figure 14 : Illustration de l'évolution de la courbure locale le long des régions curvilinéaires

Nous avons superposé sur l'image de la Figure 14, les points des axes des régions curvilinéaires principales. Il apparaît que la variation en chacun des points de l'axe de la courbure locale est faible.

En résumé, les contraintes de base caractérisant une région curvilinéaire à inclure dans le modèle que nous allons définir sont :

- Deux gradients importants localisés sur les bords de la structure curvilinéaire,
- Textures similaires sur les bords de la région curvilinéaire,
- Variation de largeur sur l'ensemble de la forme faible,
- Variation locale de largeur de la forme faible,
- Variation de courbure locale faible.

La section suivante présente la définition et la formalisation du modèle prenant en compte les observations réalisées.

2.2. Présentation du modèle

2.2.1. Structures Curvilinéaires : définition

Une structure curvilinéaire peut être définie par un ensemble de paires de points :

$$C = \{(R_i, L_i), i = 0, \dots, l\} \quad (2.1)$$

Avec l la longueur de la structure curvilinéaire (nombre de points), $l \in \mathbb{N}$

$R \begin{vmatrix} x_R \\ y_R \end{vmatrix}$ et $L \begin{vmatrix} x_L \\ y_L \end{vmatrix}$ sont des points, dans l'espace de l'image, placés sur les bords droits et gauches d'une région curvilinéaire, $x \in \mathbb{N}$ et $y \in \mathbb{N}$ sont les coordonnées dans le repère de centre Ω .




Figure 15 : définition du système de coordonnées et d'une section

NB : il est aussi possible de définir une structure à partir de l'ensemble des points de l'axe d'une structure, de la largeur locale et de l'angle que fait la perpendiculaire à l'axe avec l'axe horizontal du repère de centre Ω :

$$c = \{(A_i, w_i, \theta_i), i = 0, \dots, l\} \quad (2.2)$$

Avec :

$$A \begin{cases} x_A = \frac{x_R + x_L}{2} \\ y_A = \frac{y_R + y_L}{2} \end{cases} \text{ un point dans l'image,}$$

$$w = \sqrt{(x_R - x_L)^2 + (y_R - y_L)^2}, \text{ la largeur au point A, } w \in \mathbb{R}$$

et θ est défini par :

$$\theta = \arctan\left(\frac{(y_R - y_L)}{(x_R - x_L)}\right), \theta \in [0, 2\pi].$$

Cette définition sera utilisée par la suite pour le développement d'un descripteur spécifique aux régions curvilinéaires ainsi qu'un critère d'évaluation des performances de détection du détecteur de ces régions.

2.2.2. Régions curvilinéaires : définition

Nous définissons une région T comme un ensemble de pixels contenus au sein d'un polygone fermé défini par l'ensemble des C points de la structure.

Si B_i est l'ensemble des pixels contenus à l'intérieur du quadrilatère défini par les quatre sommets suivants : $\{R_i, L_i, R_{i+1}, L_{i+1}\}$ alors on définit T comme l'ensemble des points contenus par l'union des i quadrilatères :

$$T = \bigcup_{i=1}^{l-1} B_i \quad (2.3)$$

Cette définition sera utilisée lors de l'étude de répétabilité du détecteur. Elle nous permettra également de réaliser des comparaisons quantitatives de segmentation avec quelques détecteurs de veines dans les images de rétine, dans le chapitre suivant.

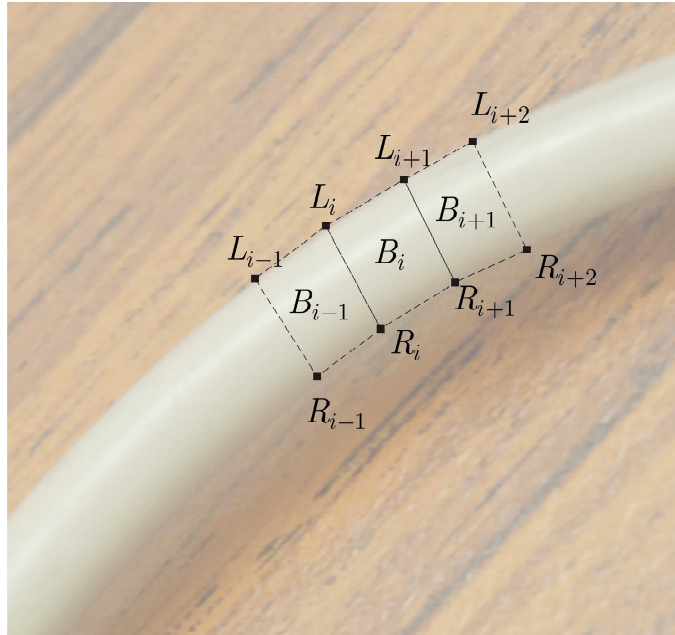


Figure 16 : Définition d'une région

2.2.3. Section : définition

Afin d'analyser les sections des formes curvilinéaires, nous nous plaçons dans le repère de centre Ω' , approximation du repère de Frenet de la courbe définissant l'un des bords de la région (Figure 15). Le signal est alors échantillonné (N échantillons) le long de la section, dans la direction du gradient déterminé au point de contour.

Dans le repère local de la section, le signal discret devient :

$f(n) \in \mathbb{R}$ défini dans l'intervalle $[0, N]$, $n \in \mathbb{N}$.

$f(n)$ peut prendre toute valeur possible calculée à partir de la luminance et/ou de la chrominance ou à partir d'informations locales de textures.

Nous pouvons maintenant rechercher n_L et n_R , les abscisses respectives des points L et R dans le repère de centre Ω' .

Pour $n \in [0, \lambda]$ et λ choisi arbitrairement (typiquement $\lambda = 4, 8$ ou 16), nous définissons quatre signaux qui serviront à caractériser la section (voir Figure 17):

$$v_l(n) = f(n + n_L - \lambda) \quad (2.4)$$

$$v_R(n) = f(n + n_R + w) \quad (2.5)$$

$$v_{SL}(n) = f(n + n_L) \quad (2.6)$$

$$v_{SR}(n) = f(n + n_R + w) \quad (2.7)$$




Figure 17 : Section dans le système de coordonnées locales

Afin de pouvoir caractériser les textures éventuellement présentes dans les différentes parties de la section, nous avons utilisé la transformée de Fourier discrète. En effet, nous nous sommes inspiré du fait que les descripteurs de Fourier généralisés pouvaient permettre une bonne discrimination de textures [Foucherot, I. & al : 2002 ; Journaux, L. & al : 2008 ; Smach, F. & al : 2007], et nous les avons appliqués ici de manière simplifiée, sur le signal 1D.

Ainsi, $V(k)$ est la transformée de Fourier discrète (TFD) du signal $v(n)$ et est définie de la façon suivante :

$$V(k) = \sum_{n=0}^{\lambda} v(n) e^{-2i\pi k \frac{n}{\lambda}} \quad (2.8)$$

Nous calculons donc $V_R(k)$, $V_L(k)$, $V_{SL}(k)$ et $V_{SR}(k)$, les TFD des quatre signaux précédemment définis après application de la méthode de Hamming [Harris, F. J. 1978] dans le but de réduire l'effet de repliement de spectre.

Afin d'évaluer le degré de similarité des textures, nous définissons ensuite la distance entre deux signaux $V_1(k)$ et $V_2(k)$ dans l'espace de Fourier de la manière suivante :

$$m(V_1(k), V_2(k)) = \frac{\sqrt{\sum_{k=0}^{\lambda} (|V_1(k)| - |V_2(k)|)^2}}{m_{\max}} \quad (2.9)$$

avec $m \in \mathbb{R}$, $0 \leq m \leq 1$,

et où m_{\max} est un facteur de normalisation, et $|V(k)|$ est le module de la TFD.

L'avantage d'utiliser cette mesure à la place d'une mesure de distance réalisée directement entre deux signaux de luminance est qu'elle permet de bénéficier de l'invariance en translation de la transformée de Fourier. Les temps de calcul seront toutefois bien sûr plus importants que si l'on utilise un gradient classique. Nous étudierons dans le chapitre suivant l'influence de la largeur de la fenêtre d'analyse sur les performances, et nous montrerons également dans le dernier chapitre que les performances de mise en correspondance sont meilleures en utilisant cette distance qu'en utilisant une différence classique de luminance.

A partir des termes précédents, on définit quatre composantes d'une fonction de coût locale qui caractérise une structure curvilinéaire :

Le score caractérisant la présence d'un contour à gauche de la section peut être estimé par :

$$P_L(n_L, w) = m(V_L(k), V_{SL}(k)) \quad (2.10)$$

Le score caractérisant la présence d'un contour à droite de la section peut être estimé par :

$$P_R(n_R, w) = m(V_R(k), V_{SR}(k)) \quad (2.11)$$

Le score caractérisant la présence d'une texture similaire à droite et à gauche de la section peut être estimé par :

$$P_S(n_R, w) = 1 - m(V_L(k), V_R(k)) \quad (2.12)$$

De plus nous introduisons dans la fonction de coût un facteur de régularisation permettant de prendre en compte le fait que la largeur d'une structure curvilinéaire est quasiment constante d'une section donnée à une autre.

Ce terme est une fonction gaussienne dont la valeur moyenne est n_R' où n_R' est déterminé à partir de la section précédente et donc l'écart type δ est arbitraire :

$$P_w(n_R) = \frac{1}{\delta\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{n-n_R'}{\delta}\right)^2} \quad (2.13)$$

Nous devons donc maximiser la fonction de coût $Q(n_L, w)$:

$$Q(n_L, w) = P_L(n_L, w) P_R(n_R, w) P_S(n_L, w) P_w(n_R) \quad (2.14)$$

La solution est composée des valeurs optimales :

$$\{n_{Lopt}, w_{opt}\} = \arg \max(Q(n_L, w))$$

$$w \in [0, w_{\max}]$$

$$n_L \in [0, n_m - 2\lambda]$$

A partir desquelles nous déduisons la valeur de n_{Ropt} :

$$n_{Ropt} = n_{Lopt} + w_{opt}$$

Nous avons choisi pour $Q(n_L, w)$ le produit des différents termes afin de garantir l'annulation de la fonction dès lors que l'un des termes est nul, et représenter ainsi la nécessité de simultanéité des différentes contraintes. Ainsi, nous évitons les phénomènes de compensation qui se produiraient si nous utilisions la moyenne des termes par exemple. Cette moyenne conduirait à la détection de sections complètement asymétriques, ce qui ne correspond pas au modèle que nous nous sommes fixé. De plus ce produit contrairement à la fonction de détection de profil curvilinéaire de Staal [Staal, J. & al : 2004], présenté dans la section consacrée à l'état de l'art sur des

méthodes de détection de veines de la rétine, permet de quantifier l'appartenance d'une section à une structure curvilinéaire. En effet, la fonction de Staal donne 1 ou -1 si une structure d'une certaine largeur présente deux contours de sens opposés et un point de crête. Dans notre cas, la valeur de réponse est comprise entre 0 et 1, ce qui permet de sélectionner les profils répondant à nos contraintes de façon plus ou moins importante. De plus, nous introduisons par rapport à Staal une contrainte vérifiant si les bords sont similaires. Cette contrainte forte permet d'obtenir des régions plus stables.

L'avantage de cette fonction de coût, comparée aux méthodes basées sur les dérivées de gaussiennes est donc d'une part qu'elle tente de prendre en compte la notion de différence de textures et d'autre part qu'elle balaye intrinsèquement une plage d'échelle qui peut être importante, puisque nous ferons typiquement varier w de 2 à 100 voir parfois 150 pixels dans des images de résolution de l'ordre de 1000x800. Nous verrons (chapitre suivant) dans la comparaison avec les résultats de Steger, qui fixe une fois pour toute la largeur d'analyse pour un problème donné, que le CRD détecte ainsi des régions sur une plus grande plage de largeur. Il serait également possible d'adopter en plus une stratégie pyramidale pour balayer une plage de largeurs plus importante, mais ceci n'a pu être réalisé au cours de ce travail de thèse faute de temps.

Les performances de la détection de section, qui conditionnent ensuite les performances globales du CRD seront étudiées expérimentalement dans le chapitre suivant, sur des signaux de synthèse d'abord, puis sur des signaux réels. Nous montrerons ainsi qu'il est robuste au bruit blanc ou naturel, parfois meilleur que ceux basés sur les dérivées de gaussiennes, et répétable.

2.2.4. Régions curvilinéaires : définition de contraintes 2D et détermination des régions

Puisque nous disposons maintenant d'un opérateur nous permettant de détecter les sections des régions curvilinéaires, il serait maintenant théoriquement nécessaire de l'appliquer en tout point de l'image et pour toutes les orientations possibles des sections. Ceci n'est pas réaliste d'un point de vue du temps de calcul, que nous avons estimé à une trentaine d'heures pour une image de résolution 800x600 et un PC standard. Or nous

souhaitons, pour les applications envisagées, obtenir des temps de traitement inférieurs à la minute. De plus, l'application en tout point ne résoudrait pas le problème de l'analyse de connexité entre chaque section. Nous nous sommes donc rapprochés ici de l'analyse de Steger qui utilise un algorithme de suivi des maxima de la réponse de son filtre ou de Martinez-Perez [Martinez-Perez, M. & al : 1999] qui utilise une phase de croissance de régions afin de regrouper les pixels considérés comme appartenant à des veines. Cependant cette dernière méthode ne garantit pas l'ordonnement des pixels de l'axe et des bords des régions détectées.

Toutefois afin de mieux sélectionner les régions les plus stables et répétables, nous avons introduit un certain nombre de contraintes supplémentaires. Nous avons donc paramétrisé la structure en utilisant une simple analyse de connexité, à partir de laquelle il est possible de définir un ensemble de contraintes 2D qui permettront de regrouper les sections appartenant à une même structure curvilinéaire.

Les observations (voir Figure 16 et Figure 15) tendent à montrer que la texture est la plupart du temps constante le long de la région curvilinéaire. Nous pouvons traduire cette observation de la manière suivante :

Si pour $n \in [n_L, n_R]$, le signal dans la section est :

$v_s(n) = f(n + n_L)$, et $V_{s,i}(k)$ est la version paramétrée de la transformée de Fourier de $v_s(n)$ alors cette contrainte 2D devient :

$$m(V_{s,i}(k), V_{s,i+1}(k)) < \varepsilon_1 \quad (2.15)$$

De même, la variation locale de largeur d'une région curvilinéaire est généralement faible (voir Figure 15). Ceci est implicite dans les méthodes basées sur une convolution avec des dérivées de gaussiennes dont les paramètres sont fixes. Nous pouvons le traduire par la contrainte :

$$|w_i - w_{i+1}| < \varepsilon_2 \quad (2.16)$$

Pour éviter de détecter des régions très bruitées, nous pouvons définir une contrainte sur la variation de courbure locale γ_i , qui doit donc être faible sur l'ensemble de la région :

$$|\gamma_i - \gamma_{i+1}| < \varepsilon_3 \quad (2.17)$$

Enfin les contours de part et d'autre de la région doivent être localement parallèles, ceci implique :

$$\frac{x_{R,i} - x_{R,i+1}}{y_{R,i} - y_{R,i+1}} - \frac{x_{L,i} - x_{L,i+1}}{y_{L,i} - y_{L,i+1}} < \varepsilon_4 \quad (2.18)$$

La position de l'axe est naturellement contrainte par la connexité entre deux points de droite (respectivement gauche) successifs combinée avec la contrainte de variation locale de largeur.

Les valeurs ε_1 , ε_2 , ε_3 et ε_4 sont des seuils choisis de manière arbitraire. L'influence de ces seuils sera étudiée dans le chapitre consacré à la répétabilité. Il est possible de les déterminer à l'aide d'une méthode d'apprentissage, par exemple pour maximiser le nombre de correspondances correctes dans les opérations d'estimation d'homographies. En ce qui nous concerne, nous avons réalisé un apprentissage consistant à choisir le meilleur ensemble de seuils à partir d'un ensemble de 98 configurations. L'expérience sera décrite dans le dernier chapitre.

L'ensemble des points vérifiant les contraintes précédemment définies est donc $S = \{C_j, j = 0, \dots, n\}$ avec $C_j = \{(R_{ij}, L_{ij}), i = 0, \dots, l_j\}$.

A partir de ces éléments et suivant les applications abordées, il est encore possible de sélectionner les régions souhaitées sur d'autres critères comme la longueur minimum ou maximum souhaitée, la largeur de section minimum ou maximum, la polarité de la région (sombre sur fond majoritairement clair ou claire sur fond majoritairement sombre).

2.3. Implémentation du détecteur

Comme nous l'avons indiqué précédemment, le détecteur que nous venons de définir devrait être appliqué en tout point de l'image, mais ceci induirait des temps de calcul trop importants. Dans le but de réduire ces temps de calcul, nous avons diminué le nombre de points candidats en n'appliquant le détecteur de sections que pour les points de contours et dans la direction du gradient. En effet, il est inutile de calculer la fonction de coût, produit des différentes contraintes, là où le gradient est nul ou quasi nul.

Les étapes du détecteur de régions curvilinéaires sont donc :

- Détection des contours, calcul de la norme et la direction du gradient en utilisant par exemple le filtre de Petrou-Kittler [Petrou, M. & al : 1991].
- Détermination des points connexes au point étudié en utilisant un algorithme de suivi de contours. Chaque ensemble de points est candidat pour devenir une structure curvilinéaire.
- Pour chaque point de contour de chacun des ensembles, nous appliquons le détecteur de section et les contraintes 2D.
- Fusion des structures connexes possédant un caractère de continuité.
- Suppression des réponses multiples.

L'ensemble de la chaîne est présenté à la Figure 18:

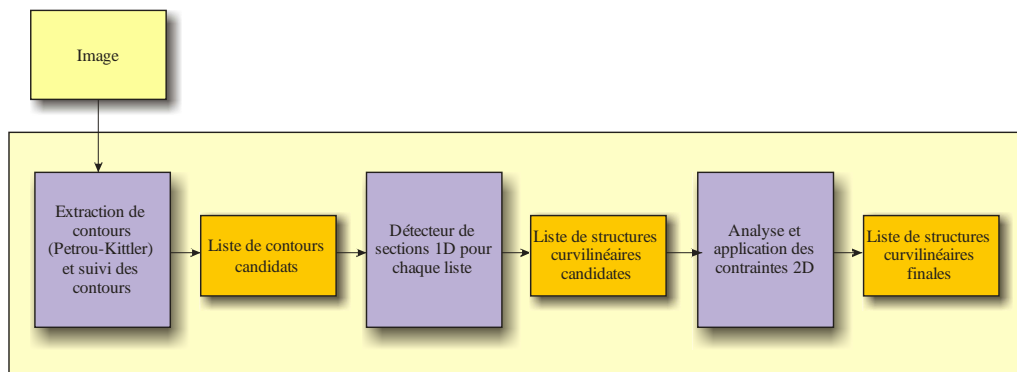


Figure 18 : Tâches principales du détecteur de régions curvilinéaires

La phase d'analyse 2D comporte cinq processus (Figure 19):

- Analyse de la variation de largeur et de courbure locales. Si plusieurs profils consécutifs candidats ne respectent pas les contraintes de variation de largeur et de variation courbure locales alors la liste à laquelle il appartient est séparée en deux. Cette phase introduit une forme de régularisation qui permet d'éliminer les sections isolées présentant des caractéristiques localement très différentes des autres. Elle permet d'obtenir des régions plus longues et finalement plus stables.
- Elimination des formes de type « carré » et « cercle ». Ces formes ont en effet la particularité de répondre aux nombreuses contraintes du modèle, sans être à proprement parler des régions curvilinéaires, dont on suppose que la longueur est supérieure à la largeur. Toutefois, ces

formes pourraient avoir une utilisé dans certaines applications, voire pour la mise en correspondance, mais n'ont pas été étudiées ici.

- Fusion des ensembles possédant des extrémités communes et ayant des propriétés de largeur et des directions communes.
- Suppression des structures ne respectant par la contrainte de longueur minimum.
- Suppression des détections multiples.

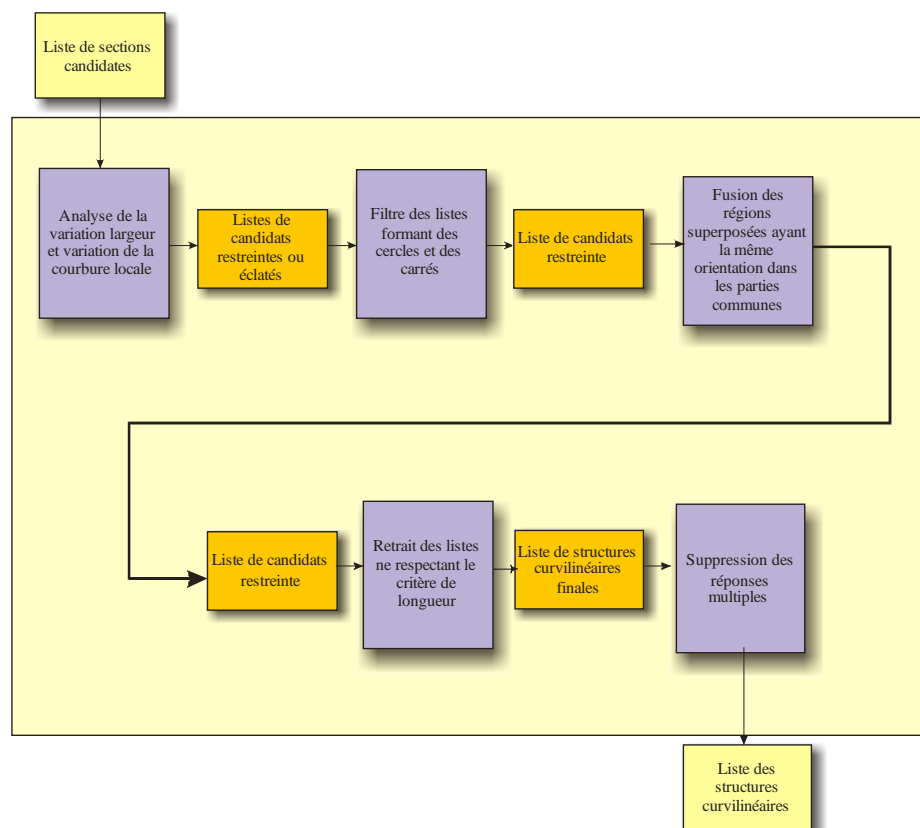


Figure 19 : Détails de l'analyse 2D

Nous avons évalué les temps de calcul de l'ensemble de la chaîne de traitement pour une dizaine d'images, de résolution 1600x1200, et en utilisant un PC standard possédant un processeur Intel core 2 Duo 2 Ghz. Le Tableau

1 résume les temps de calcul obtenus, et ce pour chaque composante du détecteur. Sans être temps réel, l'algorithme reste utilisable pour des applications pratiques, le temps total restant de l'ordre de la vingtaine de secondes, sans optimisation particulière du code (multithread, ou autre).

| | Détection de contours (Petrou-Kittler) | Suivi de contours | Détecteur de section | Applications des contraintes 2D | Temps total | Nb régions détectés |
|-------------------------|--|-------------------|----------------------|---------------------------------|----------------|---------------------|
| Temps moyen en s | 1,654 | 0,0378 | 11,728 | 4,784 | 18,2038 | 119,6 |

Tableau 1 : Temps de calcul des différents phases du CRD

2.4. Conclusion

Dans ce chapitre, nous avons présenté un détecteur de régions curvilinéaires (CRD) basé sur un modèle, qui se veut le plus répétable possible pour les opérations de mise en correspondance. Cet opérateur, partiellement basé sur l'état de l'art, comprend à la fois un détecteur de section ainsi qu'un processus d'extraction complet de régions curvilinéaires mettant en jeu des contraintes sur la largeur et la courbure de la forme, ainsi que sur les textures internes et externes à cette forme.

Dans le chapitre suivant, nous allons positionner le CRD par rapport à quelques détecteurs existants, dont celui de Steger qui peut être considéré comme généraliste, et plusieurs détecteurs spécialisés dans la segmentation de veines de la rétine. Les performances du CRD correspondant à nos attentes, nous verrons qu'il sera possible de l'utiliser pour la mise en correspondance, après avoir défini un descripteur adapté qui permettra de caractériser les régions.

Chapitre 3. Performances et applications de la phase de pré-segmentation

3.1. Introduction

Ce chapitre présente une analyse expérimentale des performances du détecteur de régions curvilinéaires pour la phase de pré-segmentation, et se terminera par deux exemples d'applications potentielles.

Afin de caractériser le détecteur le plus finement possible, nous avons tout d'abord étudié le comportement du détecteur de sections face à des situations variées (signaux de synthèse, signaux réels, répétabilité en présence de bruit, etc), avant d'étudier les performances de la phase complète de pré-segmentation, c'est-à-dire séparant les régions curvilinéaires du fond de l'image. Nous comparerons qualitativement les résultats du CRD avec ceux de Steger, et quantitativement avec des détecteurs de veines de la rétine.

3.2. Etude du détecteur de section (signaux 1D)

3.2.1. Signaux de synthèse

3.2.1.1. Signal « porte »

A titre de simple validation de principe, nous avons étudié la réponse de notre détecteur pour le signal « porte idéale » que l'on peut définir de la manière suivante :

$$f_{po}(n) = \begin{cases} H, & n < |w| \\ 0, & n > |w| \end{cases} \quad (2.19)$$

Pour la porte symétrique, et de la manière suivante

$$f_{ns}(n) = \begin{cases} H, & n < |w| \\ 0, & n < -w \\ A, & n > w \end{cases} \quad (2.20)$$

Pour la porte asymétrique.

Ce signal répond en effet à toutes les contraintes de notre détecteur de section, (grands gradients de part et d'autre du profil de la structure

curvilinéaire, bords similaires à droite et à gauche), et le détecteur se doit de répondre de manière maximale à ce type d'entrée.

Le résultat du détecteur est représenté sur la figure suivante, dans le cas d'une porte symétrique et dans le cas d'une porte asymétrique, plus éloignée du modèle souhaité :




Figure 20 : Réponse du détecteur de section pour le signal "porte idéale" (symétrique et asymétrique)

Comme indiqué dans la définition du modèle, nous déterminons la réponse maximum du détecteur en faisant varier la largeur de la région et la position de l'axe. Pour faciliter la visualisation, nous avons choisi de représenter sur les courbes uniquement la réponse maximum du détecteur pour la largeur optimum, en fonction de la position de l'axe (milieu de la section) défini par :

$$n_A = \frac{n_L + n_R}{2}$$

On peut remarquer que la réponse du détecteur est maximale pour le centre de la porte et la valeur de cette réponse est 1, et ce pour une largeur optimum automatiquement et correctement déterminée (qui vaut ici 48).

Ce motif qui peut sembler être très simple pose un certain nombre de difficultés aux méthodes de détection de régions curvilinéaires basées sur la détection des lignes de crête (voir section 1.5.2.3) car le profil de ce motif est plat.

En ce qui concerne le signal asymétrique, à peine plus proche de la réalité, le maximum est toujours bien localisé, même si la réponse est inférieure (0,36 dans ce cas et 1 dans le cas de la porte symétrique).

3.2.1.2. Modèle de ligne de Steger

Dans sa thèse [Steger, C. 1998b], Steger affirme qu'un bon compromis de modèle de ligne, tant pour les images de scènes naturelles (images aériennes contenant des routes notamment) que pour les images particulières que sont les images médicales (contenant des veines, artères), peut être défini de la manière suivante :

$$f_p(n) = \begin{cases} h(1 - (n/w)^2), & |n| < w \\ 0, & |n| > w \end{cases} \quad (2.21)$$

Sur ce type de signal, on peut s'attendre à ce que la valeur du maximum soit moins importante car les contours des bords du profil de la région sont plus « lisses » que dans le cas des deux signaux précédents. Le résultat du détecteur est représenté sur la Figure 21:




Figure 21 : Réponse du détecteur pour le modèle de ligne proposé par Steger

La position de l'axe est bien détecté (pour la bonne largeur optimum), même si la réponse maximale du filtre est inférieure à la porte idéale (ici 0.18, contre 1 pour la porte symétrique). La présence de lobes secondaires n'est pas réellement pénalisante, étant donné la dynamique de la réponse.

3.2.1.3. Signal Triangulaire

Un autre profil de ligne proposée dans la littérature [Lorenz, C. & al : 1997a ; Lorenz, C. & al : 1997b], est basé sur un profil triangulaire qu'on peut définir de la façon suivante :

$$f_t(n) = \begin{cases} h(1 - (|n|/w)), & |n| < w \\ 0, & |n| > w \end{cases} \quad (2.22)$$

Ce modèle de ligne ne correspond pas aux contraintes intégrées à notre détecteur puisqu'il ne possède pas véritablement de contours de part et d'autre de la région. Cependant les résultats présentés à la (Figure 22) montrent qu'il est possible de détecter ce genre de profil sans ambiguïté car le maximum est facilement localisable. Sa valeur est toutefois nettement inférieure à la valeur des maxima détectés pour les profils précédents.




Figure 22 : Résultats de notre détecteur pour un profil de ligne "triangulaire"

3.2.1.4. Signal « rampe »

Afin de vérifier la réponse de notre détecteur sur des signaux qui ne répondent aux contraintes de notre modèle, nous avons testé celui-ci avec le signal « rampe » défini de la façon suivante :

$$f_r(n) = \begin{cases} h, & n > w \\ 0, & n < w \end{cases} \quad (2.23)$$

Pour bon nombre d'approches basées sur l'exploitation des dérivées premières et secondes, ce type de signal pose des problèmes importants car il

gène bien souvent des fausses détections. Dans le cas de notre détecteur, nous obtenons un maximum (Figure 23), situé exactement sur la zone de transition, mais avec une valeur maximum très faible (environ 0.002, soit 40 fois inférieure à la réponse obtenue pour le signal précédent, et près de 100 fois inférieure à celle obtenue pour le modèle de ligne de Steger). On peut donc dire qu'il est sera aisé de supprimer ces fausses détections par un simple seuillage sur la valeur de $Q(n)$.




Figure 23 : Résultats du détecteur pour le signal "rampe"

3.2.1.5. Simulation de signal texturé

Afin d'illustrer la capacité du filtre à détecter des régions curvilinéaires texturées ou dont les bords sont texturés, nous avons créé un signal composé de deux sinusoides de fréquences f_1 et f_2 auxquelles un bruit blanc $B(n)$ a été ajouté. Les deux parties du signal ont même valeur moyenne, ce qui signifie qu'un filtre classique ne prenant pas en compte plusieurs plages de fréquence ne pourrait les distinguer. Ce signal est défini de la manière suivante :

$$f_p(n) = \begin{cases} h(\sin(2\pi f_1 n) + B(n)), & |n| < w \\ h(\sin(2\pi f_2 n) + B(n)), & |n| > w \end{cases} \quad (2.24)$$




Figure 24 : Signal contenant deux textures de même amplitude et réponse du détecteur




Figure 25 : Résultats de la convolution de dérivées premières et secondes de gaussienne proposées par Steger sur le signal contenant 2 textures

Sur ce signal, les méthodes basées sur l'exploitation de la convolution de convolution de dérivées première et secondes d'une gaussienne sont difficilement utilisables (Figure 25). En effet, ces filtres supposent que la forme curvilinéaire se trouve entre un contour « gauche » et un contour « droit » définis conjointement par la position du maximum de $G'(n)$ et le passage par 0 de $G''(n)$. Il apparaît sur les résultats visibles à la Figure 25 qu'il existe un nombre important de réponses multiples. De plus la valeur utilisée pour l'écart-type de la gaussienne (σ) nécessite une information *a priori* sur la largeur de la forme à étudier. Steger propose d'utiliser $\sigma = 0.3w$.

En ce qui concerne notre détecteur de section, le maximum est très facilement différenciable des maxima secondaires (Figure 25). De plus la valeur de celui-ci est très élevée (0,74) et proche de celui de la porte idéale. Ce résultat est obtenu grâce à l'utilisation de la distance entre signaux dans l'espace de Fourier.

3.2.2. Signaux réels

Afin d'étudier les performances de notre détecteur de section sur des signaux réels, nous avons pratiqué manuellement des coupes perpendiculaires à des structures curvilinéaires de manière à obtenir un signal 1D analysable par le détecteur de section.

3.2.2.1. *Signal extrait d'une image de veine de la rétine*

Le premier signal étudié a été extrait d'une image de rétine (voir Figure 26). Le nombre d'échantillons de cette coupe est de 96 pixels. Elle présente la particularité de posséder une très faible dynamique puisque la totalité des valeurs des niveaux de gris sont situés entre 100 et 120.

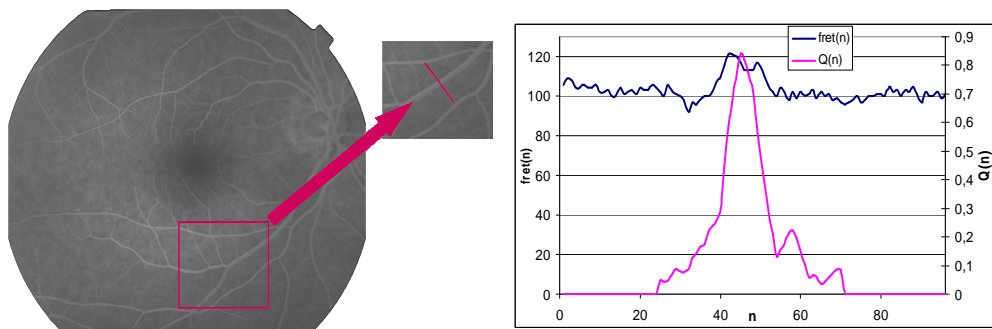


Figure 26 : Illustration de la sélection d'un signal au sein de l'image de la rétine et réponse du détecteur de section

Malgré cette faible dynamique, notre opérateur permet la détection du profil de la structure curvilinéaire représentant la veine. Le maximum du détecteur est facilement détectable et sa réponse est de 0,8, c'est-à-dire proche de la valeur obtenue pour la porte idéale.

Il est à noter que dans ce cas un filtre comme celui de Steger fonctionne également, puisque il est possible de localiser les maxima de la dérivée première $G'(n)$ et les passages par zéro de la dérivée seconde $G''(n)$ (voir Figure 27). Cependant pour obtenir une précision correcte sur la mesure de

largeur, il est nécessaire d'avoir une connaissance *a priori* sur la largeur étudiée afin de fixer l'écart type du noyau gaussien à $\sigma = 0.3w$.




Figure 27 : Résultats de la convolution avec la dérivée première d'une gaussienne

3.2.2.2. Signaux extraits d'une image aérienne

Le second type de signal réel évalué provient d'une image aérienne contenant des routes. Le but ici est de vérifier si notre détecteur répond correctement sur des coupes réalisées perpendiculairement à des routes entourées de part et d'autre de textures.

La première coupe $f_{r1}(n)$ a été choisie dans une zone où la texture (herbe) est la même de chaque côté.

La seconde coupe $f_{r2}(n)$ a été réalisée dans une zone plus fortement texturée et où la texture n'est pas la même de chaque côté de la route (herbe et haie à gauche et forêt à droite).

Le détail de la sélection de ces coupes apparaît à la Figure 28.




Figure 28 : Illustration de la sélection des signaux au sein d'une image aérienne

Le résultat du détecteur de section pour ce signal est représenté sur la Figure 29-a. Il apparaît que le maximum de détecteur de section est localisé au centre de la route, qu'il est facilement détectable et que sa valeur reste élevée (0,39).




Figure 29 : Réponse du détecteur pour la coupe contenant une route bordée de deux textures similaires (a) et de deux textures différentes (b).

Dans le cas de la seconde coupe $f_{r_2}(n)$, la route est entourée d'une prairie et d'une haie sur sa gauche et d'une forêt sur la droite. Malgré cette différence, notre modèle permet la détection de celle-ci sans problème et la valeur du maximum, (Figure 29-b) est du même ordre de grandeur que pour la coupe précédente.

Dans le cas d'une méthode à base de filtre gaussien (Figure 30) la route est bien détectable mais ici encore cette détection suppose une connaissance *a priori* de la largeur à détecter.

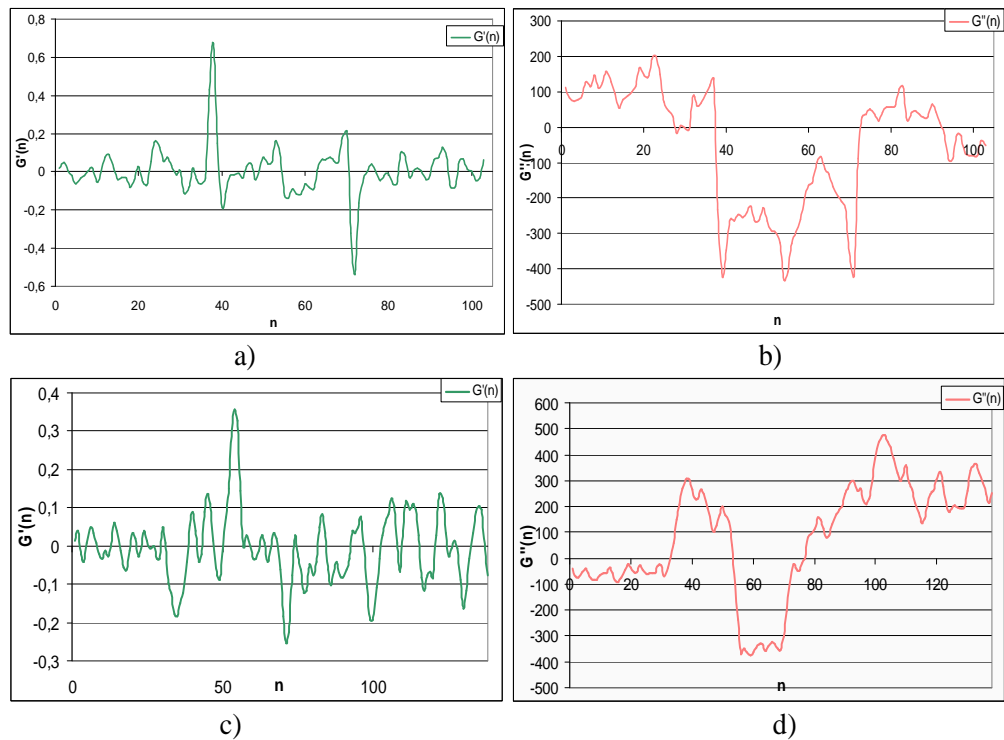


Figure 30 : Résultats de la convolution de la dérivée première d'une gaussienne avec un signal contenant une route bordée de textures similaires (a et b) et deux textures différentes (c et d).

3.2.3. Stabilité du détecteur de section

Nous avons présenté dans la section précédente des résultats qualitatifs obtenus en appliquant le détecteur sur des signaux de synthèse et sur des signaux extraits au sein d'images réelles. Nous allons maintenant présenter des résultats quantitatifs concernant la stabilité de notre détecteur de section. Nous nous intéresserons plus particulièrement à l'influence du changement du point de vue et à l'influence du bruit sur les performances de ce détecteur.

3.2.3.1. Robustesse du détecteur de section aux changements de point de vue

Pour étudier la robustesse du détecteur aux changements de point de vue, nous avons acquis 6 images d'une scène extérieure, représentée à la Figure 31. L'angle de changement de point de vue varie entre 0° et environ 60° . Cette expérience peut être considérée comme un préliminaire à l'expérience plus

complète de répétabilité de l'ensemble de la détection qui sera présentée dans le paragraphe suivant.

Nous avons effectué 10 coupes par image, exactement au même endroit et perpendiculairement à la région curvilinéaire à détecter. Ces images possèdent la propriété de comporter des objets verts (portail) sur une texture verte (herbe ou arbre). Un exemple d'une coupe réalisée dans l'une des images est représenté Figure 32.




Figure 31 : Images utilisées pour l'étude de l'influence du changement de points de vue sur le détecteur de section

La principale modification subie par les structures curvilinéaires après un changement de point de vue est la modification de la largeur apparente (de 90 à 10 pixels suivant l'angle, pour une même coupe effectuée par exemple au niveau du portail). Le but de cette étude est donc de vérifier que les déformations apportées aux signaux monodimensionnels par le changement de points de vue, n'altèrent pas la détection du profil de la structure curvilinéaire ni la précision d'évaluation de la position de l'axe et de la mesure de la largeur, qui sont utilisées ensuite par le descripteur de régions curvilinéaires de type shape context.

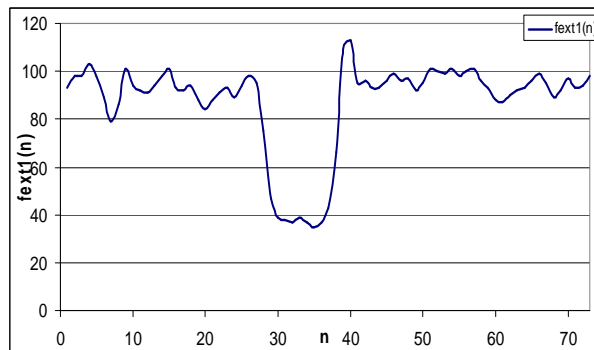


Figure 32 : Exemple de coupe extraite au niveau du portail

La mesure de performance est réalisée en comparant la mesure de position de l'axe et la valeur de largeur du profil d'une région curvilinéaire déterminée manuellement par un expert à celle déterminée par notre détecteur de section. Les résultats disponibles au Tableau 2, permettent d'affirmer que le changement de point de vue n'influence pas de manière significative le détecteur de section. En effet, la valeur moyenne de l'erreur absolue de la position de l'axe est de 1,4 pixels et celle de la valeur de largeur est 2,35 pixels.

| | Point de vue 1 | Point de vue 2 | Point de vue 3 | Point de vue 4 | Point de vue 5 | Point de vue 6 |
|--|----------------|----------------|----------------|----------------|----------------|----------------|
| Erreur absolue de position de l'axe en pixel | 2,1 | 0,8 | 1,7 | 1,6 | 1,1 | 1,1 |
| Erreur absolue de largeur détectée en pixel | 1,7 | 2,3 | 2,5 | 2,7 | 2,1 | 2,8 |

Tableau 2 : Résultats de l'étude de l'influence de la largeur sur la stabilité du détecteur de section

3.2.3.2. Robustesse du détecteur de section au bruit

La robustesse du détecteur de section a été évaluée à la fois sur des signaux de synthèse ainsi que sur des signaux réels provenant de coupes réalisées sur des images.

3.2.3.2.1. Bruit blanc additif

Pour cette étude nous avons confectionné un ensemble de signaux d'étude provenant de trois signaux pour lesquels nous avons ajouté un bruit blanc gaussien dont nous avons fait varier l'écart-type en prenant les valeurs : {1, 2, 4, 6}. Les trois signaux sélectionnés sont : le modèle de ligne proposé par Steger, le signal composé d'une texture centrale bordée d'une texture de même valeur de luminance moyenne mais de fréquence différente et enfin un signal réel provenant d'une coupe réelle réalisée dans une image contenant une rivière coulant au sein d'une forêt.

Il faut noter que la largeur des régions curvilinéaires est d'une quarantaine de pixels. La taille totale des signaux est de l'ordre d'une centaine de pixels.



Figure 33 : Image dans laquelle une coupe a été réalisée pour l'étude de l'influence du bruit sur le détecteur de section

Les résultats de cette expérience sont consignés dans le Tableau 3. On peut remarquer que, quelque soit le signal, la précision du détecteur reste peu influencée par le bruit. En effet, l'erreur maximum de position de l'axe est de 3 pixels. L'erreur de mesure de la largeur de la section de la région curvilinéaire est également de 3 pixels.

| Type de Signal | Erreur mesurée (pixels) | Ecart-type du bruit blanc gaussien | | | | |
|---|---------------------------------|------------------------------------|-----|-----|-----|-----|
| | | 0 | 1 | 2 | 4 | 6 |
| Modèle de ligne de Steger | Erreur sur la position de l'axe | 0 | 0 | 0 | 0 | 0 |
| | Erreur sur la largeur détectée | 0 | 1 | 2 | 3 | 3 |
| Signal contenant deux textures de valeurs moyennes identiques | Erreur sur la position de l'axe | 1 | 1 | 1 | 3 | 1 |
| | Erreur sur la largeur détectée | 2 | 2 | 2 | 3 | 2 |
| Signal réel | Erreur sur la position de l'axe | 0.5 | 0.5 | 0.5 | 1.5 | 2.5 |
| | Erreur sur la largeur détectée | 1 | 1 | 0 | 0 | 2 |

Tableau 3 : résultats de l'étude de robustesse au bruit du détecteur de section

3.2.3.2.2. Bruit naturel

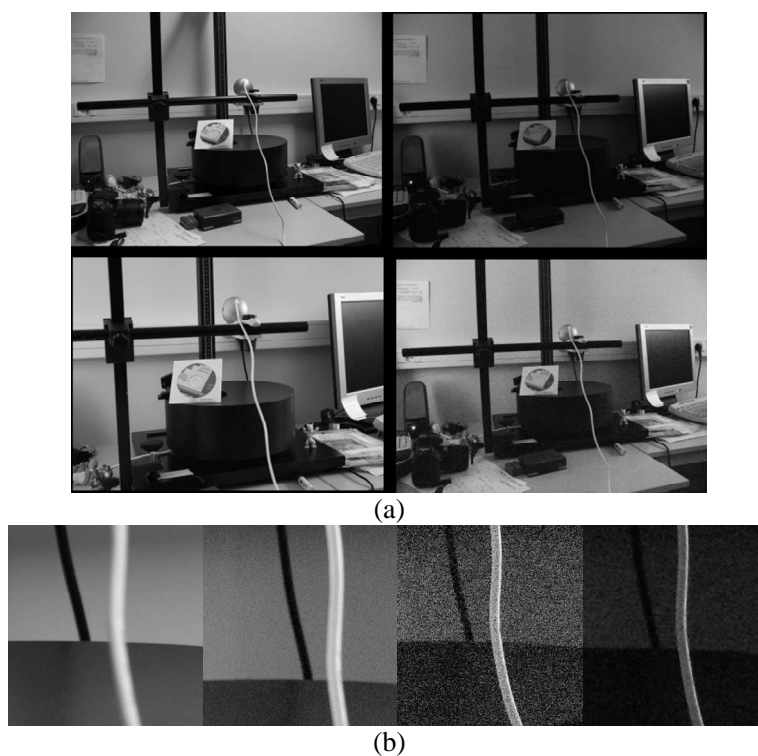


Figure 34 : Exemple d'images utilisées pour évaluer l'influence du bruit naturel sur le détecteur de section (a) et agrandissements (b)

Dans le but d'évaluer l'influence du bruit naturel sur le détecteur de section, nous avons réalisé une base constituée d'images de la même scène acquise en faisant varier la sensibilité (de 25 à 1600 ISO) de deux appareils numériques

de marque et de qualité différentes.. Quelques exemples d'images obtenues sont présentés à la Figure 34-a. Des agrandissements (Figure 34-b) permettent de mieux visualiser l'impact du bruit sur les formes curvilinéaires. Les résultats représentés par le Tableau 4 permettent de conclure que notre détecteur est très peu sensible au bruit car l'erreur de position de l'axe et l'erreur de mesure de la largeur ne varient pas de manière significative malgré l'augmentation de la valeur du bruit.

| Sensibilité(ISO) | 25 | 100 | 200 | 400 | 800 | 1600 |
|--|----|-----|-----|-----|-----|------|
| Erreur absolue de position de l'axe en pixel | 2 | 1.5 | 2 | 3 | 1 | 1 |
| Erreur absolue de largeur détectée en pixel | 4 | 7 | 4.5 | 5 | 2 | 4 |

Tableau 4: résultats de l'étude de l'influence du bruit naturel sur les performances du détecteur de sections

3.3. Performances de la phase de pré-segmentation (signaux 2D)

L'étude est composée de deux parties, l'une traitant d'images de synthèse, l'autre d'images réelles. Dans les deux cas, l'étude vise à montrer de manière qualitative et parfois quantitative la capacité du détecteur à réaliser une pré-segmentation de l'image qui permet d'éliminer le fond et de ne conserver que les régions curvilinéaires. Dans le cas des images réelles, nous avons cherché à positionner le CRD par rapport à l'état de l'art, en comparant résultats ou des performances de segmentation de notre détecteur avec différents détecteurs disponibles dans la littérature. Ainsi, nous proposons une comparaison qualitative avec le détecteur de Steger, et notamment une comparaison quantitative avec des méthodes de segmentation des veines de la rétine.

3.3.1. Etude sur des images de synthèse

Les deux premières images de synthèse étudiées comportent des formes de base extrêmement simples : une barre noire sur fond blanc et une couronne

blanche sur fond noir (voir Figure 35). Dans les deux cas, les deux motifs sont correctement détectés. On peut aussi souligner que contrairement à certaines méthodes de détection de régions curvilinéaires, notamment les méthodes à base de filtre gaussien [Steger, C. 1998a ; Steger, C. 1998b], il n'est pas nécessaire d'avoir une méthodologie pour détecter les formes claires sur fond foncé et une méthodologie pour détecter les formes foncés sur fond clair.




Figure 35 : Exemple de résultats de segmentation sur des images de synthèse très simples

La seconde image étudiée (Figure 36-a) contient une forme texturée en forme « d'arche » et d'une forme plus rectiligne positionnée verticalement sous l'arche. La (Figure 36-b) présente le résultat de détection pour une contrainte sur la variation de largeur $\varepsilon_2 = 0.7$. On remarque que la région curvilinéaire de plus grande taille est détectée en une seule partie (Figure 36-b), malgré l'étranglement qu'elle présente dans sa partie gauche. Dans le cas où la contrainte de variation de largeur est plus restrictive, c'est-à-dire $\varepsilon_2 = 0.15$, la région est détectée en deux parties (Figure 36-c).

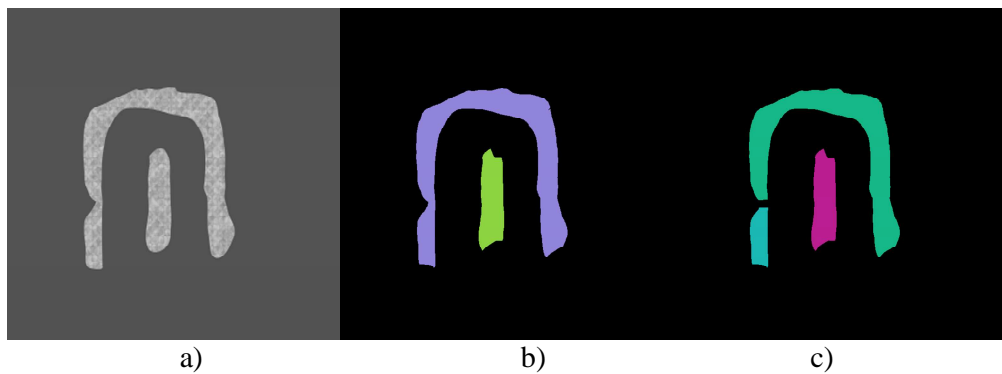


Figure 36 : Image contenant deux régions curvilinéaires texturées (a) et le résultat du détecteur de régions curvilinéaires avec contrainte de variation de largeur faible (b) avec contrainte de variation de largeur plus restrictive (c)




Figure 37 : Image possédant une région curvilinéaire bordé d'un dégradé et d'une région homogène (a), résultats du détecteur de régions curvilinéaires (b) et résultats du détecteur de Steger avec présence de biais (c)

La troisième image étudiée (Figure 37-a) contient une région curvilinéaire possédant sur un coté un dégradé de niveaux de gris et de l'autre coté une région de niveau de gris homogène. Le résultat de notre détecteur présenté à la Figure 37-b. La région est correctement détectée, ce qui n'est pas le cas avec la méthode de Steger qui est basée sur des filtres gaussiens. En effet, la ligne noire représentée à la Figure 37-c correspond à l'axe de la région curvilinéaire détectée par l'opérateur de Steger. On remarque qu'un biais est introduit par l'effet de lissage des gaussiennes et nécessite l'usage d'un algorithme de correction.

La dernière image synthèse étudiée (voir Figure 38-a) contient deux régions curvilinéaires, l'une rectiligne et l'autre courbe. Ces deux régions sont placées sur une texture au niveau de gris moyen dégradé. Les résultats de détection sont présentés à la Figure 38-c pour une largeur de fenêtre d'analyse de Fourier égale à 16 et à la Figure 38-d pour une largeur de fenêtre d'analyse de Fourier égale à 4.

Les deux régions obtenues sont scindées en plusieurs parties, ce qui est logique car en plusieurs endroits du dégradé, le contour est inexistant (Figure 38-b). Toutefois, l'utilisation d'une plus grande taille d'analyse de Fourier permet de limiter l'influence de ce phénomène. Les régions détectées en d) représentent en effet 71% de la surface totale théorique des régions curvilinéaires présentes dans l'image, contre seulement 51% pour celles détectées en c). Nous verrons plus en détail l'influence de la largeur de la fenêtre d'analyse dans le dernier chapitre.




Figure 38 : Résultats pour une image comportant 2 régions curvilinéaires sur fond texturé (a). Points de contours utilisés pour initialiser le détecteur (b). Résultats du détecteur pour une largeur de FFT de 4 (c) et 16 (d)

3.3.2. Comparaison qualitative avec Steger sur des images réelles

Afin de comparer qualitativement les performances de segmentation de notre détecteur, nous présentons dans cette section quelques exemples de résultats obtenus par notre détecteur et celui de Steger [Steger, C. 1998b].

Pour chacun des exemples, nous avons représenté l'image originale et deux extraits agrandis de cette image dans lesquels les résultats de Steger sont incrustés (les contours des régions sont en vert, et les points de l'axe en rouge). Dans la partie inférieure, nous avons représenté le résultat du CRD sous forme de régions.

Les six premières images sont issues de la base de Berkeley [Martin, D. & al : 2001] et sont habituellement utilisées pour comparer des algorithmes de segmentation. Elles n'ont donc pas été choisies a priori comme étant des images contenant des régions curvilinéaires particulières. Les septième et huitième images ont été acquises par nos soins afin de souligner les bonnes performances du CRD en environnement texturé.




Figure 39 : résultats de segmentation du détecteur de Steger et du CRD

Le premier exemple (voir Figure 39), est l'image d'un avion sur une piste d'atterrissage et d'un piéton se déplaçant sur cette piste. On peut noter que les deux détecteurs permettent l'extraction des régions formées par les

jointures des plaques de bétons utilisées pour constitué la piste. Ces régions sont plus morcelées dans le résultat du CRD que dans celui du détecteur de Steger. Les principales différences de détection résident au niveau de l'échelle des régions détectées. En effet le détecteur de Steger permet la détection des lettres positionnées sur l'appareil (régions de faible largeur) alors que le CRD permet la détection de formes d'une largeur beaucoup plus importante comme certains panneaux métalliques formant la carlingue de l'avion, ou encore l'ombre du piéton.




Figure 40 : résultats de segmentation du détecteur de Steger et du CRD

Le deuxième exemple est l'image d'un cerf dans une prairie avec une forêt en arrière plan. Sur cet exemple, le résultat des deux détecteurs est très semblable puisqu'une partie des pattes de l'animal et ses bois sont détectés. Cependant le CRD permet la détection d'une partie plus importante des pattes.




Figure 41 : résultats de segmentation du détecteur de Steger et du CRD

Le troisième cliché étudié est une image contenant un surfeur au sein d'un rouleau formé par une vague, la place étant en arrière plan à droite.

Sur cet exemple comme pour le cas de l'avion, l'échelle des régions détectées par le CRD et le détecteur de Steger est différente. Le détecteur de Steger va repérer les formes de faible largeur alors que le CRD va localiser les largeurs

plus importantes. Par exemple dans l'approche de Steger seule une ombre sur les jambes est détectée alors que le CRD détecte les jambes en grande partie.




Figure 42 : résultats de segmentation du détecteur de Steger et du CRD

Le quatrième exemple est l'image d'un tigre se déplaçant dans un cours d'eau. Sur cette image, les performances de détection des deux méthodes sont proches. En effet, les rayures de la fourrure du tigre sont en grande partie détectées dans les deux cas. Une partie des roseaux placés devant le tigre est également détectée dans les deux cas. Cependant le CRD ne détecte pas les rayures (trop courtes) dans la région de la queue de l'animal contrairement à la méthode de Steger. Enfin on peut noter qu'aucune des deux méthodes ne détecte correctement la queue de l'animal en tant que région à part entière.

En effet les rayures du pelage en font une texture ayant une échelle trop importante devant la largeur de la queue.




Figure 43 : résultats de segmentation du détecteur de Steger et du CRD

Le cinquième exemple, est une image qui contient peu de régions curvilinéaires. Les seules régions curvilinéaires de cette image sont les berges du cours d'eau, ainsi que les régions formées par les montagnes de l'arrière plan. Ces régions sont globalement extraites par les deux détecteurs. Cependant le détecteur de Steger produit des fausses détections autour du rocher en forme de « dent » ainsi que dans la région des rochers.




Figure 44 : résultats de segmentation du détecteur de Steger et du CRD

Le sixième cliché étudié est l'image d'une pyramide. Sur cette image qui ne contient a priori aucune région curvilinéaire, le CRD donne quelques fausses détections au sein de la pyramide (les autres régions détectées sont liées à un « effet de bord » qui provient du cadre gris entourant l'image). Dans le cas du détecteur de Steger, le nombre de fausses régions détectées est légèrement plus important.




Figure 45 : résultats de segmentation du détecteur de Steger et du CRD

L'avant dernier cas est plus difficile puisqu'on cherche à détecter des branches de faible largeur sur un sol composé d'herbe et de petites feuilles. Sur ce cliché, notre détecteur se révèle bien plus performant que celui de Steger qui détecte un nombre important de régions curvilinéaires dans la pelouse. Le CRD permet de filtrer efficacement ce type de faux positifs grâce aux contraintes 2D, auxquelles nous avons ajouté ici une contrainte sur la longueur minimum des régions. De plus à certains endroits, le détecteur de Steger produit des erreurs de mesure de largeur importantes à cause de variation de luminosité (variation de clair à sombre) au sein de la région. Dans ce cas précis, le calcul des distances dans l'espace fréquentiel que nous utilisons dans le détecteur de section permet une meilleure détection de la largeur. Sur cette image, nous avons pu estimer le nombre de pixels bien

classés en le comparant à une segmentation manuelle. Nous obtenons pour le CRD une précision de 98,6%.




Figure 46 : résultats de segmentation du détecteur de Steger et du CRD

Le dernier cas, est un cas aussi difficile que le cas précédent puisqu'on cherche un filet de but de football présentant en arrière plan de l'herbe. Sur cette image, notre détecteur est légèrement plus performant que celui de Steger puisqu'il ne génère aucune fausse détection dans la pelouse. Encore

une fois, c'est le calcul des distances dans l'espace de Fréquentiel qui permet d'éviter ses fausses détections.

Les conclusions de cette étude comparatives sont donc les suivantes : d'une manière générale, l'opérateur de Steger détecte des régions plus fines que le CRD, mais aussi que l'on peut considérer comme moins stables pour la mise en correspondance, puisque qu'il détecte de nombreuses formes dans des zones texturées. Steger, grâce à une étape particulière de son algorithme, détecte également les intersections des régions, ce que le CRD ne fait pas, puisque ces intersections ne répondent pas au modèle que nous nous sommes fixé. D'autre part, grâce au parcours d'échelle inclus dans le détecteur de section, le CRD détecte des régions larges, que Steger ne détecte pas du tout. Enfin, l'ensemble des contraintes 2D appliquées dans le CRD permet de sélectionner les régions par famille (longueur, largeur, etc), ce qui n'est pas inclus dans la version de base de Steger.

Nous pouvons également conclure de cette série d'expérience que les régions curvilinéaires sont très souvent présentes et nombreuses dans les images, celles présentées ici ayant été choisies aléatoirement dans une base de données standard. Nous avons mené ainsi de nombreuses autres expériences sur cette base et d'autres images, qui tendent à conforter ce fait

3.3.3. Comparaison quantitative – images de la rétine

Nous proposons dans cette étude de comparer le CRD à d'autres détecteurs disponible dans la littérature [Chaudhuri, S. & al : 1989 ; Jiang, X. & al : 2003 ; Journaux, L. & al : 2008 ; Martinez-Perez, M. & al : 1999 ; Niemeijer, M. & al : 2004 ; Stall, J. & al : 2004 ; Zana, F. & al : 2001] en utilisant un ensemble d'images de la rétine, nommé DRIVE³, pour lesquelles nous possédons la vérité de terrain. Cette vérité de terrain a été obtenue à l'aide d'un expert qui a segmenté manuellement les images.

Pour cette application, nous avons adapté notre détecteur afin de ne localiser que les régions curvilinéaires foncées sur un fond clair. De cette manière, nous ne détectons que les régions correspondant aux veines.

³ <http://www.isi.uu.nl/Research/Databases/DRIVE/>

Les résultats globaux de précision sont donnés au Tableau 5 ainsi que par la courbe ROC (voir Figure 47) Il apparaît que notre détecteur présente une précision très proche des meilleurs détecteurs (0,928 pour le CRD et 0,947 pour le meilleur détecteur, celui de Staal).

En ce qui concerne la courbe ROC, on peut constater que le CRD se positionne au même niveau que l'approche de Martinez-Perez.

| Méthode | Précision |
|----------------|-----------|
| Humain | 0,947 |
| Staal | 0,944 |
| Niemeijer | 0,941 |
| Zana | 0,9377 |
| CRD | 0,928 |
| Jiang | 0,921 |
| Martinez-Perez | 0,9181 |
| Chaudhuri | 0,87 |

Tableau 5 : Performances de segmentation

Cependant, l'inspection visuelle de résultats disponible à la Figure 39, à la Figure 40 et à la Figure 41 permettent de dire que la légère différence de performances est lié essentiellement au fait que le CRD ne détecte pas les régions de largeurs inférieures à 4 pixels. En effet le détecteur a été créé dans le but de l'utiliser dans le cadre d'applications de mise en correspondance. Il rejette donc systématiquement les régions de trop faible largeur qui pourraient se révéler instables pour les applications de mise en correspondance.

De plus les résultats obtenus par notre détecteur sont, d'un point de vue visuel, moins bruités que certains détecteurs, notamment celui de Martinez-Perez qui produit systématiquement une sur-segmentation à l'extrémité des veines (Figure 39-e Figure 40-e et Figure 41-e).

Enfin, l'avantage de notre méthode est qu'elle ne nécessite pas obligatoirement d'ensemble d'image d'apprentissage.

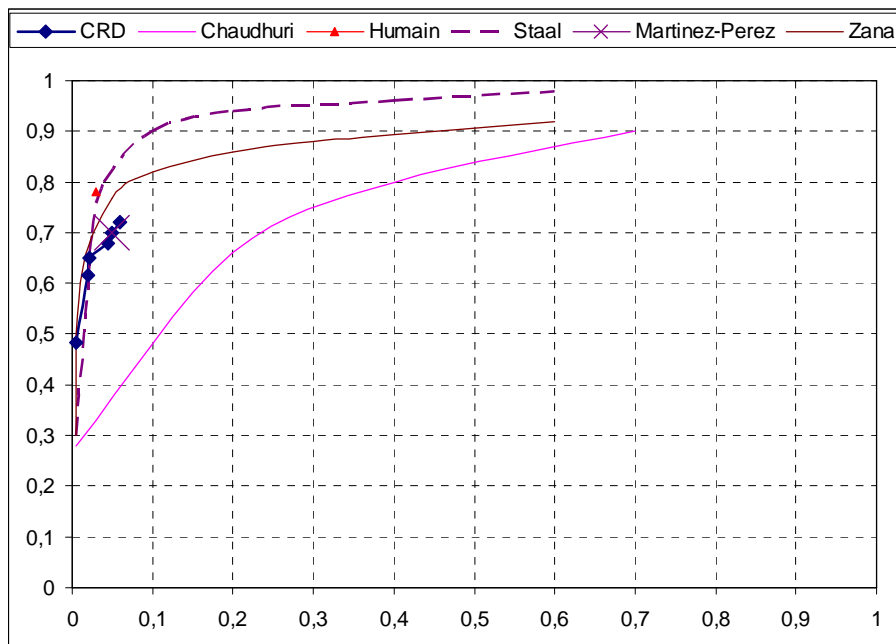


Figure 47 Courbe ROC des différentes méthodes utilisées

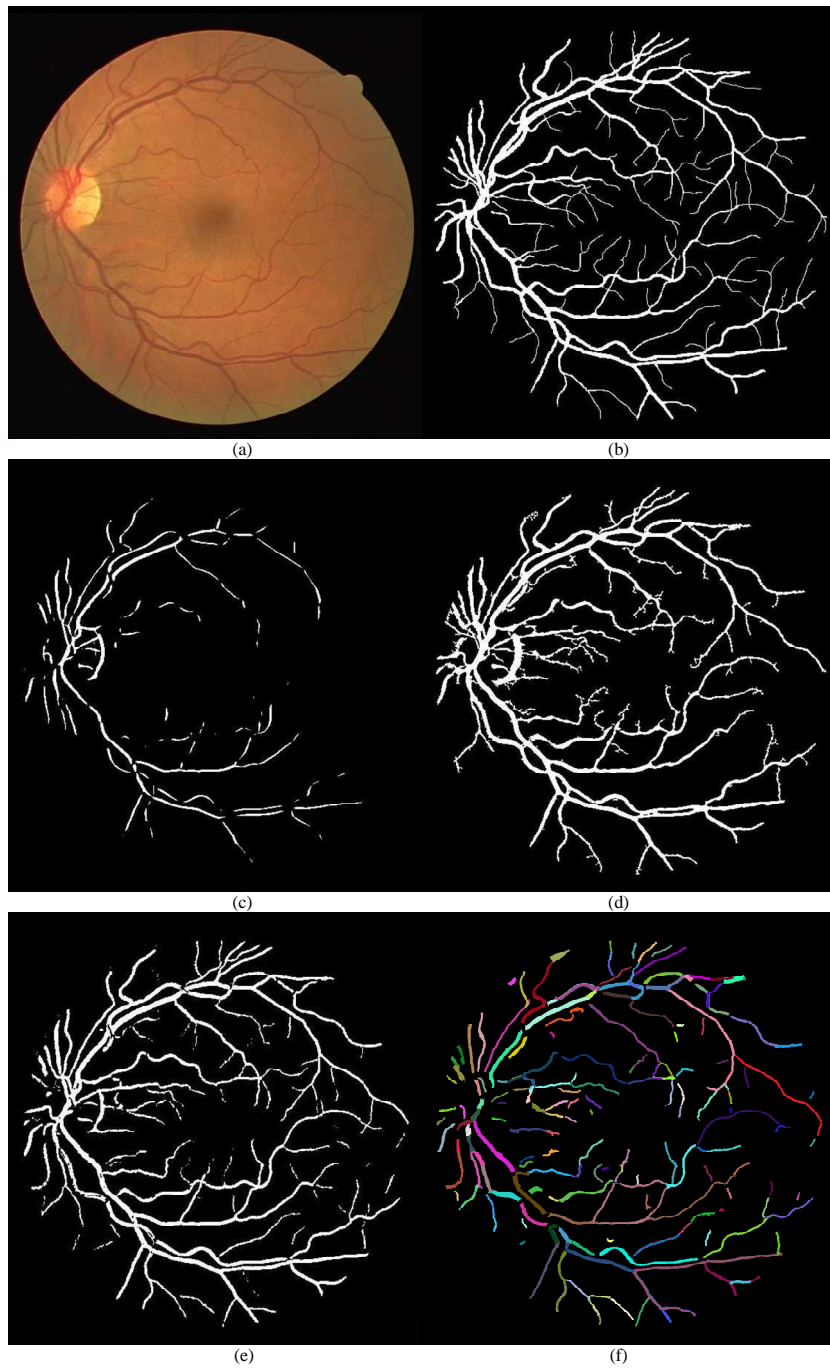


Figure 48 : résultats de segmentation (a) Image Originale (b) segmentation manuelle (c) Chaudhuri (d) Martinez-Perez (e) Staal (f) CRD




Figure 49 : résultats de segmentation (a) Image Originale (b) segmentation manuelle (c) Chaudhuri (d) Martinez-Perez (e) Staal (f) CRD




Figure 50 : résultats de segmentation (a) Image Originale (b) segmentation manuelle (c) Chaudhuri (d) Martinez-Perez (e) Staal (f) CRD

3.4. Applications de la phase de pré-segmentation

3.4.1. Détection de cordons de colle

La première application que nous présentons, est la détection de cordons de colle positionnés sur les culasses de moteurs de voitures avant le montage.

En effet lors de l'assemblage final de ces moteurs, un cordon de colle est disposé sur la culasse. Cet étape de la conception est critique car elle garanti directement la qualité de fonctionnement du moteur. Ce cordon est déposé à l'aide d'un robot possédant les informations CAO du cordon. Cependant, au cours de ce processus, pour différentes raisons, des modifications du chemin suivi par les cordons sont effectuées manuellement par les opérateurs. Afin de reporter ces modifications en bureau d'étude, il est nécessaire détecter les cordons réalisés en atelier et de recréer le fichier CAO correspondant, et ce le plus automatiquement possible.

Actuellement une méthode basée sur la squelettisation a été mis en place par l'entreprise concernée. Une des limites de cette méthode est qu'elle demande une intervention manuelle de l'opérateur, qui doit cliquer sur chaque début de cordon afin d'initialiser l'algorithme.

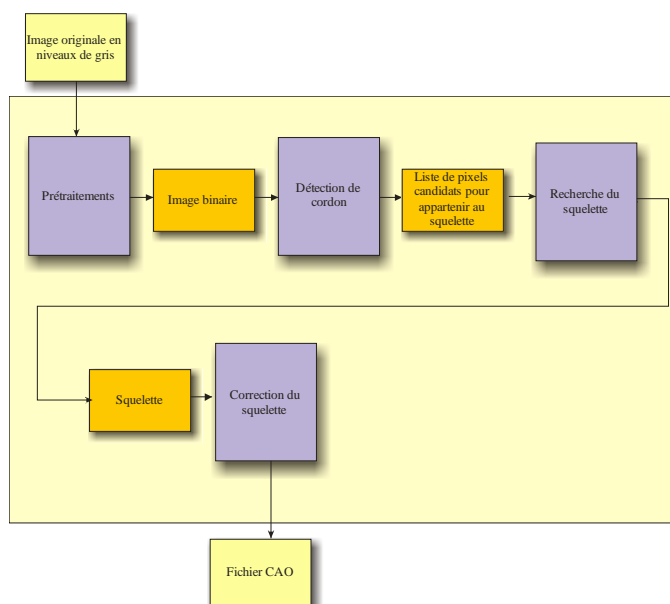


Figure 51 : Méthodes de détection du cordon actuellement utilisée

Nous proposons de remplacer la chaîne de traitement actuelle en utilisant directement le détecteur de régions curvilinéaires afin de mesurer la largeur en tout point (Figure 52).




Figure 52 : Exemple de résultats de détection automatique de cordons utilisant le CRD

Les cordons situés dans les deux images ci-dessus sont automatiquement détectés, grâce au fait que ces cordons sont les régions curvilinéaires les plus étroites et les plus longues présentes dans l'image. Pour éliminer d'éventuelles fausses détections, il est très aisé d'adapter les contraintes 2D ou d'ajouter des contraintes sur la luminance moyenne des régions afin par exemple d'éliminer les régions claires.

3.4.2. Détection de l'aorte dans les images IRM

Une des applications potentielles du détecteur de régions curvilinéaires est la détection de l'aorte. En effet, sur les images provenant d'imageur à résonance magnétique selon des coupes sagittale, l'aorte apparaît comme une structure curvilinéaire. Actuellement, ces images sont utilisées par les médecins pour déterminer le risque d'accident cardio-vasculaire d'un patient (risque de rupture d'anévrisme). Pour déterminer ce risque, certaines mesures du diamètre de l'aorte sont réalisées sur les images (voir Figure 53). Cependant il n'est pas toujours aisé de réaliser cette mesure car il n'est pas rare d'être en présence d'images très bruitées (à cause des turbulences créés par la circulation du sang) et/ou des contours très mal définis, ce qui rend une mesure de largeur imprécise.

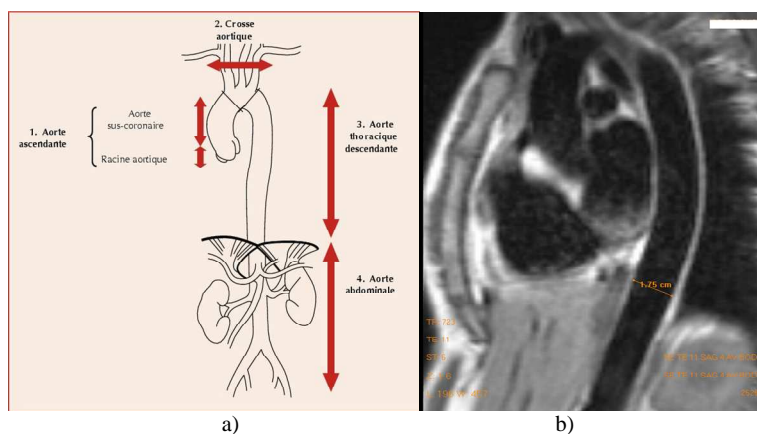


Figure 53 : Différentes parties composant l'aorte (a) et mesure actuellement pratiquée (b).

Dans une optique d'aide au diagnostic, nous proposons d'utiliser notre détecteur de régions curvilinéaires afin d'isoler l'aorte du fond et de mesurer la largeur de l'aorte en tous points.

| | Cas 1 | Cas 2 | Cas 3 | Cas 4 | Cas 5 | Cas 6 |
|--|-------|-------|-------|-------|-------|-------|
| Aorte descendante détectée (%) | 85,4 | 88,2 | 92,3 | 96,1 | 89,2 | 93,5 |
| Aorte ascendante Et descendante détectée (%) | 76,3 | 74,1 | 69,9 | 80,3 | 62,4 | 62,9 |

Tableau 6 : Résultats de détection de l'aorte

Les résultats préliminaires présentés à la Figure 54, permettent de dire que la détection de l'aorte dans sa partie descendante (voir Figure 53-a) est possible dans de nombreux cas (la région la plus longue a été sélectionnée : elle correspond la plupart du temps à l'aorte). Pour chacune des 6 images présentées à la Figure 54-a, nous avons réalisé une segmentation manuelle puis comptabilisé les pixels de l'aorte correctement classés par le CRD. Les résultats de détection reportés dans le Tableau 6 tendent à montrer qu'il est possible dans la plupart des cas de détecter automatiquement au moins 85% des pixels de l'aorte descendante. Les cas des images de la Figure 54-b n'ont pas été reportés, puisque dans ce cas, la forme la plus longue n'était pas l'aorte. Il serait aisé d'éviter ces fausses détections par définition préalable d'une région d'intérêt plus restreinte.

En ce qui concerne la partie ascendante de l'aorte, la détection est rarement possible car cette partie de l'artère ne répond pas à notre modèle. En effet, dans ces régions, les contours sont très mal définis et les bords sont rarement similaires, ce qui rend la réponse de notre détecteur très faible. Cependant pour procéder à une détection complète de l'aorte, il envisageable d'utiliser les détecteur de régions curvilinéaires pour la détection de la partie descendante et une méthode à base de contours actifs [Kass, M. & al : 1988] pour la détection de la partie ascendante.




Figure 54 : Exemple de détection de l'aorte : détections correctes (a), fausses détections (b)

Chapitre 4. Descripteurs généralistes et descripteurs de régions curvilinéaires

4.1. Introduction

Suivant la méthodologie générale présentée dans l'introduction de ce manuscrit et rappelée Figure 55, il est nécessaire de caractériser les régions curvilinéaires extraites par le détecteur précédemment décrit, pour pouvoir réaliser l'opération de mise en correspondance.

Ce chapitre est consacré à dans un premier temps, à un état de l'art des différents descripteurs de régions locales disponibles dans la littérature. Dans un second temps, nous présenterons un descripteur spécifique, dérivé des précédents, et adapté à la caractérisation de régions curvilinéaires.

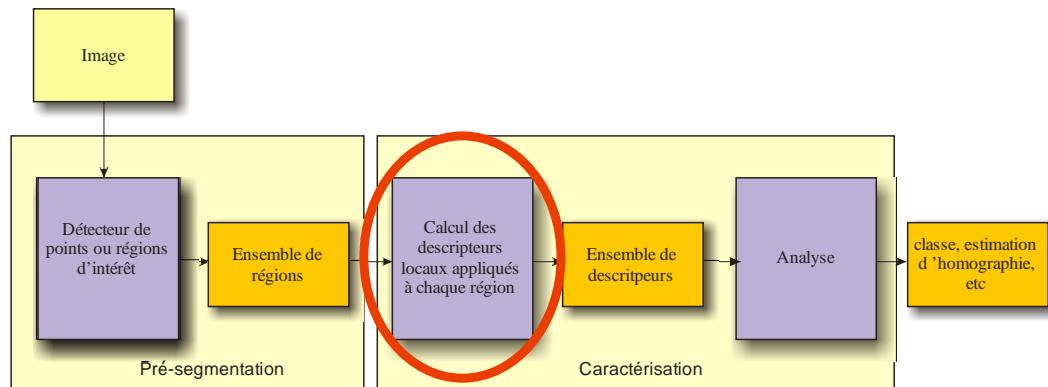


Figure 55 : Méthodologie générale

4.2. Les descripteurs généralistes

4.2.1. SIFT

Les descripteurs SIFT ont été proposés par Lowe [Lowe, D. 2004]. Un descripteur est un histogramme 3D de la position et de l'orientation du gradient. La position est quantifiée par une grille 4x4 (Figure 56) et l'orientation du gradient est quantifiée suivant huit orientations. Le résultat est donc descripteur de dimension 128.

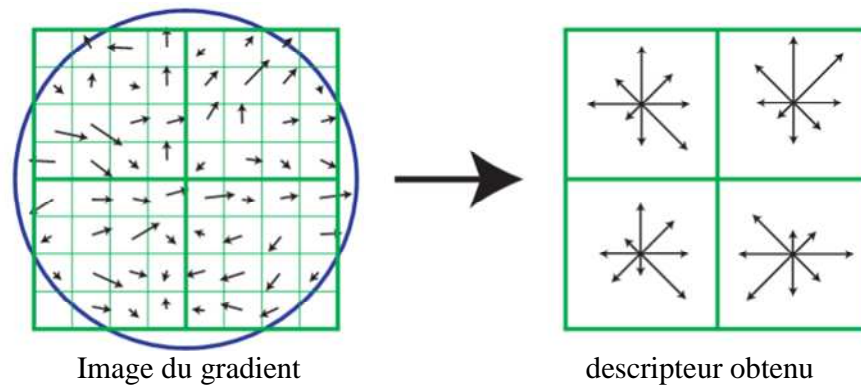


Figure 56 : Illustration du principe de SIFT

4.2.2. PCA-SIFT

Le descripteur « PCA-SIFT » est un vecteur des gradients de l'image dans la direction x et y calculée au sein d'une fenêtre de taille 41×41 représentant une région normalisée et dont les orientations principales ont été alignées avec les directions canoniques du repère de l'image. Prenant en compte les effets de bord, le vecteur contient finalement $39 \times 39 \times 2 = 3042$ éléments. Il faut noter que ce vecteur est normalisé entre 0 et 1 de manière à annuler l'influence de la variation de l'intensité lumineuse. Par la suite, la dimension de ce vecteur est réduite en utilisant l'analyse en composantes principales. Le choix de la dimension finale est en fait un compromis entre les performances souhaitées et le temps de calcul. L'auteur montre qu'une réduction à 36 dimensions est un bon compromis.

4.2.3. GLOH

GLOH (Gradient location-orientation histogram) est introduit en 2005 par Mikolajczyk dans [Mikolajczyk, K. & al : 2005a]. GLOH est une extension de SIFT qui a pour but d'avoir un meilleur pouvoir discriminant et une meilleure robustesse que l'original. Pour cela l'auteur propose de faire le calcul de SIFT au sein d'une grille de type « log-polaire » (Figure 57).



Figure 57 : Illustration de la grille log-polaire utilisée

Cette grille possède 3 valeurs dans la direction radiale (les valeurs du rayon sont : 6, 11 et 15) et 8 secteurs dans la direction angulaire. Il faut noter que le secteur central n'est pas divisé selon la direction angulaire. La direction du gradient est échantillonnée en 16 secteurs. On obtient donc un descripteur de dimension 272. Cette dimension peut être réduite, en conservant une partie des vecteurs de l'analyse en composantes principales (ACP) [Sirovich, L. & al : 1992] calculée sur un grand nombre de régions locales issues d'un ensemble d'apprentissage. Dans la partie expérimentale de son article, Mikolajczyk [Mikolajczyk, K. & al : 2005a] propose de conserver les 128 plus grands vecteurs propres de l'ACP.

4.2.4. SURF

Présenté en 2006 par Bay dans [Bay, H. & al : 2006], SURF est l'acronyme de « Speeded Up Robust Features ». SURF reforme à la fois un détecteur de régions d'intérêt et un descripteur quatre fois plus rapide que SIFT [Bay, H. & al : 2006]. Le détecteur de régions d'intérêt est basé sur un « détecteur de hessien-rapide » utilisant l'accélération de l'image intégrale [Viola, P. & al : 2001] pour le calcul du Hessien. Le vecteur de descripteurs est obtenu de la manière suivante : on découpe la région étudiée avec une grille d'échantillonnage 4x4. Pour chaque sous région, on forme le vecteur

$$v = \left(\sum_{x,y} d_x(x,y), \sum_{x,y} d_y(x,y), \sum_{x,y} |d_x(x,y)|, \sum_{x,y} |d_y(x,y)| \right)$$

où d_x et d_y représentent le résultat du produit entre une ondelette de Haar et la sous-image. Pour une région donnée, le descripteur de SURF possède donc une dimension égale à 64.

Comme on peut le voir dans [Bay, H. & al : 2006], les performances de SURF sont égales ou très légèrement inférieures à SIFT. Cependant les temps de

calcul sont nettement inférieurs à ceux de SIFT ce qui en fait un opérateur très largement utilisable dans les applications « temps-réel ».

4.2.5. Spin images

Le détecteur « spin images » est introduit en 2003 par Lazebnik dans [Lazebnik, S. & al : 2003]. Le descripteur « spin images » est un histogramme de la position quantifiée des pixels et de leurs intensités. Un histogramme quantifiant l'intensité en 10 secteurs est calculé au sein de 5 anneaux englobant le centre d'une région. La dimension d'un descripteur « spin images » est donc 50.

4.2.6. Invariants différentiels

L'une des plus anciennes méthodes de caractérisation locale consiste à décrire une région par l'ensemble des dérivées de l'image. Cet ensemble de dérivées locales porte le nom de « Local Jet » dans la littérature [Koenderink, J. J. 1990]. Elles sont calculées en utilisant des filtres gaussiens (Figure 58) pour plus de stabilité. La dimension du descripteur dépend du nombre d'invariants obtenu, selon l'ordre des dérivées utilisées. Il apparaît dans l'application d'indexation d'images développée par Schmid [Schmid, C. & al : 1997], que l'utilisation des invariants jusqu'à l'ordre 3 permet d'obtenir une caractérisation suffisamment riche pour caractériser l'imagette, et rendre la description invariante à la rotation.




Figure 58 : Filtres gaussiens permettant de calculer les dérivées nécessaires à l'obtention des invariants différentiels

Des versions de ce descripteur prenant en compte la couleur ont été développées par Gouet [Gouet, V. & al : 1998 ; Gouet, V. 2000 ; Montesinos, P. & al : 2000]. Les auteurs montrent que l'utilisation de la couleur permet de

limiter le calcul des dérivées à l'ordre 1, ce qui permet de réduire l'influence du bruit introduit par des dérivées d'ordre important.

4.2.7. Steerable filters

Les « steerable filters » sont introduits par Freeman dans [Freeman, W. & al : 1991] en 1991. La démarche retenue pour calculer les invariants à partir des « steerable filters » est très proche de la démarche utilisée pour les invariants différentiels, à ceci près que les dérivées utilisées ici sont directionnelles. Dans [Mikolajczyk, K. & al : 2005a], l'auteur propose d'utiliser quatre directions qui sont $\{0^\circ, 90^\circ, 180^\circ \text{ et } 270^\circ\}$. L'un des principaux avantages d'utiliser des dérivées directionnelles est d'avoir un plus grand nombre d'invariants sans qu'il soit nécessaire de calculer des invariants d'ordre important, qui ont pour effet indésirable d'introduire du bruit.

4.2.8. Filtres complexes

Les méthodes de calcul d'invariants à base de filtres complexes sont très proches des deux approches précédentes : « steerable filters » et les invariants différentiels. Ces invariants sont calculés en utilisant des filtres définis par l'équation suivante :

$$K_{mn}(x, y) = (x + iy)^m (x - iy)^n G(x, y)$$

où G est la fonction gaussienne.

La Figure 59 représente le module de 8 exemples de filtres complexes d'ordre $m + n = 6$.

Dans [Mikolajczyk, K. & al : 2005a], l'auteur utilise 15 filtres, soit un descripteur de dimension 15, pour réaliser son étude comparative.




Figure 59 : Filtre utilisé pour calculer les invariants basés sur les filtres complexes

4.2.9. Descripteurs basés sur les moments

Les descripteurs basés sur les moments sont introduit par Van Gool dans [Van Gool, L. & al : 1996]. Ils sont définis par l'équation suivante :

$$M_{pq}^a = \frac{1}{xy} \sum_{x,y} x^p y^q [I_d(x, y)]^a$$

où $p+q$ est l'ordre du moment, a est le degré et I_d est le gradient de l'image calculé dans la direction d . Dans plusieurs applications, les auteurs [Mikolajczyk, K. & al : 2005b ; Van Gool, L. & al : 1996] utilisent deux directions pour le gradient (horizontale et verticale) et dix moments par direction. On obtient donc un descripteur de dimension vingt. Les moments d'ordre 0 et de degré 0 ne sont généralement pas utilisés dans le vecteur descripteur. On peut noter que la version originale des invariants basés sur les moments a été appliquée sur des images couleurs.

D'autres familles de moments complexes permettent d'obtenir des descripteurs invariants à la translation et à la rotation. C'est notamment le cas des moments de Zernike. Présenté en 1980 par Teague [Teague, M. 1980], les moments de Zernike $A_f(n, m)$ d'une image I sont les projections de l'image sur la base $\{V_n(r, \theta)\}$ et donc par :

$$A_f(n, m) = \frac{m+1}{\pi} \sum_x \sum_y I(x, y) V_{nm}(x, y) \quad (2.25)$$

avec : $V_{nm}(r, \theta) = R_{nm}(r) e^{-in\theta}$ si on l'exprime en coordonnées polaires.

$$\text{et le polynôme radial } R_{nm}(r) = \sum_{s=0}^{\frac{m-|n|}{2}} \frac{(-1)^s (m-s)! r^{m-2s}}{s! \left(\frac{m+|n|}{2} - s\right)! \left(\frac{m-|n|}{2} - s\right)!}$$

Wallin dans [Wallin, A. & al : 1988] décrit une famille de descripteurs invariants à la rotation obtenus à partir du module des moments de Zernike. Le principal avantage des descripteurs des moments de Zernike est le faible niveau de redondance d'information contenue dans les différents invariants. Choksuriwong [Choksuriwong, A. & al : 2005] propose une application de reconnaissance de forme par approche locale en utilisant les 72 premiers invariants de Zernike.

4.2.10. Les descripteurs généralisés de Fourier

Dans le cadre de la thématique de reconnaissance de formes en « temps-réels » développés au sein du laboratoire Le2i, nous avons contribué au développement d'un descripteur basé sur la transformée de Fourier. Ainsi, les descripteurs de Fourier généralisés ont été définis par l'équation suivante [Smach, F. & al : 2007]

$$D_f(\lambda) = \int_0^{2\pi} |\hat{I}(\lambda, \theta)|^2 d\theta \quad (2.26)$$

où \hat{I} est la transformée de Fourier de l'image I .

En pratique les descripteurs de Fourier sont calculés à partir de la somme des valeurs du module de la transformée, sur des cercles concentriques de rayon r . La première valeur de la transformée de l'image $\hat{I}(0,0)$ est utilisé pour normaliser les composantes du descripteur afin de les rendre plus robustes aux changements d'éclairage.

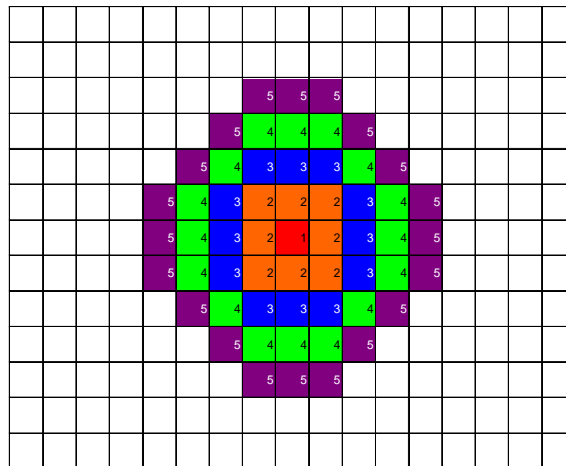


Figure 60 : Illustration du calcul des descripteurs sur les cercles concentriques

La dimension d'un vecteur de caractérisation obtenu avec les descripteurs généralisés de Fourier est $(N/2) - 1$ ou N est la taille de la région en pixels. Les performances de ces descripteurs ont été évaluées dans le cadre d'une application de reconnaissance de formes par approche globale [REF fethi cedric].

Au cours de la phase d'apprentissage (Figure 61-a), l'image d'entrée est une image couleur (RGB). Pour chaque canal de couleur nous appliquons la FFT 2D. Ainsi, les descripteurs de Fourier généralisés sont calculés indépendamment pour chaque couleur. Les trois vecteurs obtenus, chacun de dimension 63, sont regroupés en un seul vecteur de dimension 189. Ce vecteur d'invariants est alors utilisé pour alimenter un classifieur de type SVM [Vapnik, V. 1995] (« Support Vector Machines ») en phase d'apprentissage. Au cours de cette phase, l'algorithme d'apprentissage des SVM est appliqué et donne un modèle (ensemble des vecteurs supports et coefficients associés).

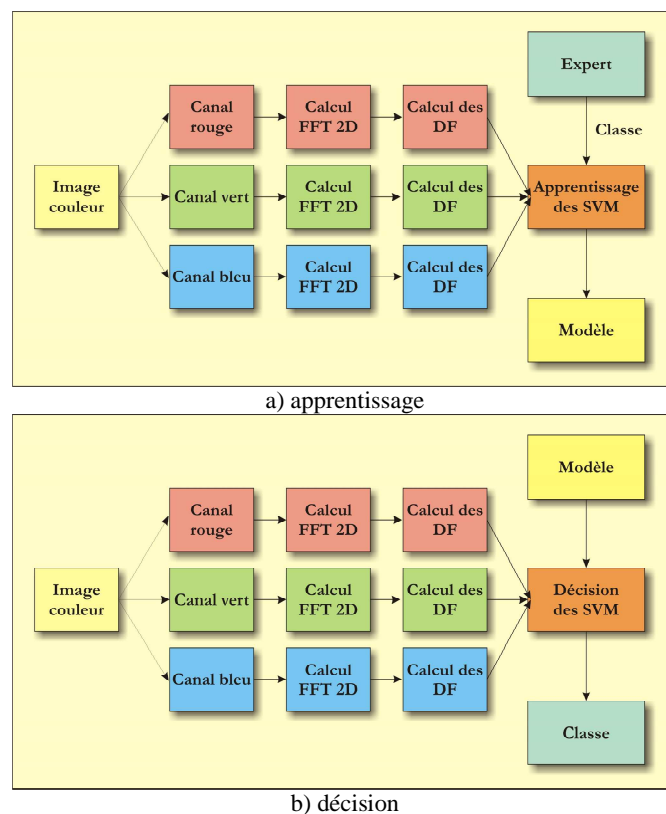


Figure 61 : Protocole d'évaluation des descripteurs

Au cours de la phase de décision (Figure 61-b), les descripteurs sont calculés de la même manière que pendant la phase d'apprentissage. La classification s'effectue directement grâce à la fonction de décision des SVM appliquée en utilisant le modèle généré pendant la phase d'apprentissage. Nous avons

validé ces descripteurs sur différentes bases : une base d'objets usuels dite COIL-100 [Nene, S. A. & al : 1996] et une base d'images couleurs de visages AR-Face [Martinez, A. M. 2000].

| | Invariants Zernike | Descripteurs Fourier |
|------------|-----------------------|-------------------------|
| Erreur (%) | 0.22 % | 0.09 % |

Tableau 7 : Performances de classification pour la base COIL-100



Figure 62 : Exemple d'images de la base COIL

Les performances obtenues par notre descripteur sur les deux bases étudiées sont nettement supérieures à celles obtenues par les invariants issus des moments de Zernike. Dans le cas de la base COIL-100 notre détecteur obtient des performances de classification de 0,09% contre 0,22% pour les invariants de Zernike (voir Tableau 7). Sur la base d'images couleurs de visages, les différences de performances sont bien plus importantes puisque notre descripteur permet d'obtenir une erreur de classification de 2,31% (voir Tableau 8) contre 10,6% pour les invariants de Zernike.

D'autres résultats et des descriptions plus détaillés sont donnés dans [Smach, F. & al : 2007] .




Figure 63 : Exemple d'images de la base AR-Face

| | <i>Invariants Zernike</i> | <i>Invariants Fourier</i> |
|------------|-------------------------------|-------------------------------|
| Erreur (%) | 10.6% | 2.31% |

Tableau 8 : Performances de classification pour la base AR-Face

Nous n'avons pas, faute de temps, pu évaluer la pertinence de l'utilisation de ces descripteurs dans le cadre de la détection de régions curvilinéaires. Toutefois, nous nous en sommes inspirés pour la définition du détecteur de section, dans lequel nous déterminons également une distance dans l'espace de Fourier. Il serait envisageable d'utiliser les descripteurs généralisés également pour différencier les textures dans des imagerie, ce qui pourrait améliorer les performances du détecteur de section, mais augmenterait considérablement les temps de calcul.

4.2.11. Shape context

Le descripteur « shape context » est présenté dans [Belongie, S. & al : 2002] par Belongie en 2002. La motivation principale de l'auteur est de proposer un descripteur qui caractérise une région par la distribution de ces contours. De cette manière, aucune information concernant le fond de l'image ne servira à caractériser la région étudiée. Pour cela, Belongie définit un « shape context »

comme un histogramme 3D de la position et l'orientation des points de contours. Les contours sont extraits en utilisant le détecteur de Canny [Canny, J. 1986]. La position est quantifiée en utilisant une grille log-polaire à 9 secteurs dont la dimension radiale prend les valeurs {6, 11 et 15}. L'orientation est quantifiée en utilisant 4 secteurs (horizontale, verticale et les deux diagonales). On obtient donc un descripteur à 36 dimensions.

Dans [Mikolajczyk, K. & al : 2005a], l'auteur propose, dans le but d'accroître les performances du détecteur, de pondérer les points contribuant à l'histogramme par la norme du gradient.

4.3. Les descripteurs de type shape context adaptés aux régions curvilinéaires

La description des régions curvilinéaires est un problème complexe. En effet, un nombre important de pixels situés à proximité d'une région curvilinéaire sont en général étrangers à cette région et ne permettent pas de la caractériser. Il est donc très peu indiqué d'utiliser les méthodes à bases d'images locales pour décrire les régions curvilinéaires. En effet, en prenant une boîte englobante carrée autour d'une région, il est fort probable que cette image contienne plus d'information du fond que d'information pertinente. Pour cette raison, nous avons proposé, en collaboration avec Michal Perdoch et Jiri Matas du Center for Machine Perception (Prague) d'introduire un nouveau descripteur spécifique à la caractérisation des régions curvilinéaires nommés : « Curvilinear Region Shape Descriptor » (CRSD).

Ce descripteur est une extension du descripteur « shape context » de Belongie [Belongie, S. & al : 2002] utilisant une idée proposée dans la méthode de découpage géométrique de Chum et Matas [Chum, O. & al : 2006]. Dans cet article, Chum et Matas suggèrent d'utiliser un découpage géométrique uniquement sur des zones d'un voisinage contenant des caractéristiques similaires. Ces caractéristiques peuvent être la couleur, l'histogramme de la couleur, le spectre fréquentiel...

On peut donc définir le descripteur « curvilinear region shape descriptor » de la façon suivante :

Pour une structure curvilinéaire $C_t = \{(A_i, w_i, \theta_i), i = 0, \dots, l_t\}$ donnée et un vecteur de k mesures $P_t = (p_{t1}, \dots, p_{tk})$, où p_{ij} est une grandeur (largeur ou autre) caractérisant le ième point de l'axe de la structure, on pose

φ_p l'ensemble de toutes les régions curvilinéaires $C_u = \{(A_{ui}, w_{ui}, \theta_{ui}), i = 0, \dots, l_u\}$ présentes dans un voisinage de rayon $R_{ii} = w_{ii} \cdot \sigma$ (Figure 64) qui ont des propriétés P_u similaires, c'est à dire respectant la contrainte suivante : $d(P_i, P_u) < \Delta$.

Δ et σ sont des paramètres du détecteur qui spécifient le niveau de similarité et la taille de la voisinage de mesure.

$d(.,.)$ est une distance ou toute autre mesure de similarité.

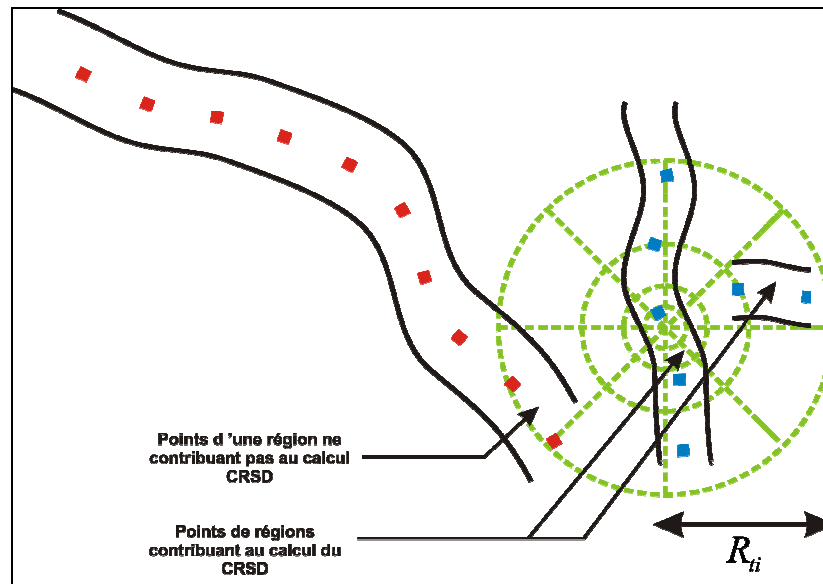


Figure 64 : Principe de calcul du CRSD

En pratique le descripteur est un histogramme d'orientations calculé dans une grille de type « log-polaire » centrée sur un point de l'axe A_{ii} d'une région curvilinéaire $C_i = \{(A_{ii}, w_{ii}, \theta_{ii}), i = 0, \dots, l_i\}$ similaire à celle du descripteur GLOH [Mikołajczyk, K. & al : 2005a]. Cependant contrairement à GLOH, nous n'utilisons pas l'orientation du gradient mais l'orientation des structures curvilinéaires $C_u \in \varphi_p$. En effet chaque structure curvilinéaire $C_u \in \varphi_p$ contribue au secteur $(\theta_i - \theta_u)$ de l'histogramme en coordonnées « log-polaire » relatif à C_u .

L'ensemble de processus formant un descripteur est présenté à la Figure 65 .




Figure 65 : "Curvilinear Region Shape Descriptor". (a) Point de l'axe des régions curvilinéaires (1/5). (b) Pré-segmentation, tous les points jaunes présentent des caractéristiques similaires. (c) grille « log-polaire » du descripteur.

Chapitre 5. Répétabilité et robustesse de la détection des régions curvilinéaires appliquée à la mise en correspondance

5.1. Méthodologie

Dans cette partie nous évaluerons quantitativement les performances de notre détecteur de régions curvilinéaires. Nous allons étudier en détail la répétabilité de la détection des régions curvilinéaires dans son ensemble, d'abord en étudiant l'influence des différents paramètres du CRD, et plus spécifiquement la largeur d'analyse de Fourier, puis en suivant pour cela le protocole utilisé par Mikolajczyk [Mikolajczyk, K. & al : 2005a] qui fait actuellement référence en matière de comparaison de performances de détecteurs associé à un descripteur.

Notre but sera donc de montrer que les régions curvilinéaires peuvent apporter un gain non négligeable dans les opérations de mise en correspondance.

Nous terminerons par un exemple d'application du CRD à l'estimation d'homographies, en comparant les résultats obtenus avec les MSER.

5.2. Critère d'évaluation

5.2.1. Critères d'évaluation existants

Mikolajczyk et Schmid ont proposé une méthode d'évaluation des détecteurs de régions dans [Mikolajczyk, K. & al : 2005b]. Cette méthode permet d'évaluer différents détecteurs (Harris-Affine, Hessian-Affine, MESR, IBR, EBR et le détecteur de saillance de Kadir & Brady [Kadir, K. & al : 2001 ; Kadir, K. & al : 2004]) en utilisant trois critères qui sont :

- La répétabilité,
- Le nombre de mises en correspondance correctes,
- Le pourcentage de mises en correspondance correctes.

Mikolajczyk évalue la répétabilité à partir d'une mesure du recouvrement de deux régions. En effet, la probabilité de mettre en correspondance deux régions augmente lorsque l'erreur de recouvrement de celles-ci diminue. Afin d'obtenir une comparaison entre les différents détecteurs, toutes les régions

obtenues par les différents types de détecteurs sont représentés par des ellipses. La définition de l'erreur de recouvrement est la suivante :

$$\varepsilon_s = 1 - \frac{R_{\mu_a} \cap R_{(H^T \mu_b H)}}{R_{\mu_a} \cup R_{(H^T \mu_b H)}} \quad (2.27)$$

où R_{μ} est une région de forme elliptique. H est l'homographie permettant de passer de l'image I_a à l'image I_b . $R_{\mu_a} \cup R_{(H^T \mu_b H)}$ est l'union et $R_{\mu_a} \cap R_{(H^T \mu_b H)}$ est l'intersection des deux régions.

Les deux régions se correspondent au sens du recouvrement, si ε_s est suffisamment faible, c'est-à-dire si $\varepsilon_s < \varepsilon_0$.

.insi, dans [Mikolajczyk, K. & al : 2005b], Mikolajczyk affirme qu'une erreur de recouvrement de $\varepsilon_0 = 0.5$ entre deux régions permet encore de les mettre en correspondance avec succès. Cependant lors de l'étude expérimentale proposée dans l'article, ce paramètre est fixé à 0.4.. On comptabilise alors les régions vérifiant ce critère comme des correspondances possibles.

Le score de répétabilité, pour une paire d'images donnée, est donc le rapport du nombre de régions se correspondant au sens du recouvrement, sur le plus petit des deux nombres de régions détectées dans les images.

Le score de correspondance (matching score), au sens de la correspondance prenant en compte les descripteurs, est le rapport entre le nombre de correspondances correctes et sur le plus petit des deux nombres de régions détectées dans les images.

Une correspondance est considérée comme correcte si elle respecte la contrainte de recouvrement et si les régions concernées sont les plus proches dans l'espace des descripteurs, au sens de la distance euclidienne.

5.2.2. Critères d'évaluation du détecteur de régions curvilinéaires

5.2.2.1. Recouvrement

Les performances du descripteur CRSD dépendent de la qualité de la pré-segmentation, c'est-à-dire de la qualité du détecteur de régions curvilinéaires. Dans le but d'évaluer quantitativement cette pré-segmentation, nous proposons la mesure de recouvrement suivante :

Soient C_r et C_t des structures curvilinéaires dans l'image de référence et dans l'image de test.

Soit $R = \{(x_i, y_i, w_i, \theta_i) \in C_r\}$ et $T = \{(x_i, y_i, w_i, \theta_i) \in C_t\}$ les ensembles de pixels contenus dans l'union des quadrilatères de C_r et C_t dotés des propriétés locales des régions (largeur et orientation des sections en tout point).

Soit H_r la transformation qui transforme les pixels de l'image test dans l'image référence et T' la région transformée de T .

Soit $R \cap T' = \{(x_i, y_i, w_i, w_j, \theta_i, \theta_j) \mid x_i = x_j \wedge y_i = y_j\}$ l'intersection entre R et T' .

Soit $R \cup T' = \{(x_k, y_k, w_k, \theta_k) \mid (x_k, y_k, w_k, \theta_k) \in R \vee (x_k, y_k, w_k, \theta_k) \in T'\}$ l'union entre R et T' .

On définit la fonction de qualité de recouvrement entre R et T' par :

$$q(R, T') = \frac{\sum_{R \cap T'} e^{-\left(\frac{(w_i - w_j)^2}{\alpha^2} + \frac{(\theta_i - \theta_j)^2}{\beta^2} \right)}}{\sum_{R \cup T'} \frac{1}{w_R^2}} \quad (2.28)$$

où α et β sont les variations tolérées sur la de largeur et l'orientation. Pour estimer la répétabilité de recouvrement pour une paire d'images, il faut mesurer la moyenne de la qualité du recouvrement pour toute l'image. Une valeur élevée pour la répétabilité de recouvrement indique une bonne répétabilité pour le descripteur CRDS.

L'avantage de cette mesure est qu'elle permet de prendre en compte la qualité de l'orientation de chaque section de la forme en plus des considérations de largeur, en tout point de la structure. Il s'agit donc plus d'une mesure de recouvrement de structures que de recouvrement de régions.

5.2.2.2. *Mise en correspondance*

Dans notre cas, la méthode de mise en correspondance utilise deux critères. Le premier est la distance euclidienne entre descripteurs CRDS pour deux régions. La seconde est une mesure de similarité de la cohérence géométrique

entre les régions voisines des deux régions étudiées. Nous avons ajouté cette mesure car le pouvoir discriminant du descripteur seul n'est pas toujours suffisant. En effet, comme l'affirme l'auteur dans [Mikolajczyk, K. & al : 2003], un unique descripteur a un pouvoir discriminant faible alors qu'un ensemble de caractéristiques d'un voisinage, qui préserve les relations géométriques après un changement arbitraire de conditions, peut permettre de mettre en correspondance deux régions sans ambiguïté. Ce type de méthode combinant descripteurs locaux et information sur la cohérence géométrique est souvent utilisé avec succès dans la littérature. On peut citer notamment : [Brown, M. & al : 2002 ; Mikolajczyk, K. & al : 2005b ; Schaffalitzky, F. & al : 2002 ; Schmid, C. & al : 1997 ; Tell, D. & al : 2002]. Cette mesure de similarité de cohérence géométrique est utilisée pour pondérer la distance entre descripteurs.

Dans notre cas, une mise en correspondance est donc considérée comme correcte si, pour une région donnée, le plus proche voisin dans l'espace des descripteurs pondérés par la mesure de cohérence géométrique, vérifie la relation définie par l'homographie reliant les deux images. Il faut noter que cette homographie est considérée comme « la vérité de terrain » car elle a été obtenue manuellement.

5.3. Evaluation de l'influence des paramètres du CRD

Dans le but de sélectionner une configuration optimale de l'ensemble des paramètres du détecteur de sections curvilinéaires, nous avons réalisé un ensemble d'expériences en faisant varier les quatre paramètres qui nous ont paru primordiaux, à savoir :

- la valeur du seuil qui détermine si un profil candidat analysé par le détecteur de section peut appartenir ou non à une région curvilinéaire. Pour ce paramètre, nous avons utilisé les valeurs suivantes {0.001, 0.008, 0.01, 0.02}.
- la tolérance de variation de largeur locale ε_2 . Nous avons utilisé les valeurs suivantes {0.1, 0.3, 0.5, 0.7}
- la largeur λ de la fenêtre d'analyse de la TFD. Les valeurs choisies sont : {4, 8, 16}

- la longueur N des sections analysées par le détecteur de section. Ce paramètre est couplé au précédent, c'est-à-dire que les sections seront de taille $N = 40$ pour $\lambda = 4$, $N = 60$ pour $\lambda = 8$ et enfin $N = 120$ si $\lambda = 16$.

Il faut noter que tous ces combinaisons de paramètres ont été testée en utilisant soit la version du détecteur fonctionnant pour des images en niveaux de gris soit en utilisant une version conçue pour les images couleurs. Toutes ces combinaisons produisent un ensemble de 96 configurations.

L'influence des ces paramètres a été évaluées sur un ensemble de 26 paires d'images, en utilisant les critères définis précédemment, c'est-à-dire en observant la qualité de la pré-segmentation (mesure du recouvrement) ainsi que le pourcentage et le nombre de correspondances correctes.

L'ensemble des résultats et des images utilisées, a été consigné en annexe. L'examen de ces résultats nous a permis de conclure d'une part qu'une valeur de recouvrement élevée indique bien qu'une réussite de mise en correspondance est très probable et d'autre part qu'il n'existe pas de configuration idéale absolue. Cependant la configuration suivante semble un bon compromis :

- Largeur de la fenêtre d'analyse de la FFT : $\lambda = 4$
- Variation de largeur : $\varepsilon_2 = 0.3$
- Seuil du détecteur de section égal à 0.008

Pour l'étude de robustesse présentée dans la section suivante, nous avons utilisé cette configuration systématiquement.

5.4. Evaluation de l'influence du gradient calculé dans l'espace de Fourier sur les performances de mise en correspondance.

Dans le but de déterminer l'influence du calcul des distances dans l'espace fréquentiel, utilisées dans le détecteur de section (P_L, P_R et P_S voir page 48). Nous proposons l'étude de l'influence de cette taille sur les performances de mise en correspondances. Pour cela, nous utilisons 4 paires d'images (voir Figure 66), pour lesquelles nous avons déterminé manuellement l'homographie représentant le changement de point de vue entre les deux

images. Pour chaque paire d'images, nous déterminons le pourcentage de recouvrement ainsi que le pourcentage de correspondances correctes. Pour cet ensemble d'images, nous avons fait varier la largeur de la fenêtre d'analyse de la FFT, et nous avons comparé les résultats obtenus avec la distance calculée sur le signal d'origine.

| Largeur de la fenêtre d'analyse de la FFT (pixels) | 0 (sans FFT) | 4 | 8 | 16 | 32 |
|--|--------------|------|------|------|------|
| Recouvrement moyen pour les 4 paires d'images (%) | 14,7 | 16,6 | 16,3 | 18,7 | 12,1 |
| Correspondances correctes pour les 4 paires d'images (%) | 16,1 | 26,1 | 35,2 | 30,2 | 13,7 |

Tableau 9 : Résultats de l'étude l'influence du gradient calculé dans l'espace fréquentiel

Les résultats de recouvrement et le pourcentage de correspondances correctes sont reportés dans le Tableau 9. On observe que l'influence de la largeur de la fenêtre d'analyse de la FFT, sur le taux de recouvrement est relativement faible. Cependant, l'influence sur le pourcentage de correspondances correctes est plus importante. En effet, il apparaît que le fait de calculer les distances dans l'espace fréquentiel permet d'augmenter significativement les performances de mise en correspondances, le pourcentage de correspondances correctes étant jusqu'à plus de deux fois plus important avec une largeur de fenêtre de $\lambda = 8$ pixels (35,2%) que sans FFT (16,1%). Toutefois, l'intérêt de cette transformée diminue lorsque la largeur augmente au-delà de $\lambda = 16$ pixels.



Figure 66: Paires d'images utilisées pour déterminer l'influence de λ sur les performances de mise en correspondance

5.5. Robustesse du détecteur

A partir des critères d'évaluation que nous venons de définir, nous proposons d'évaluer les performances de notre détecteur vis-à-vis des transformations suivantes :

- Changement de point de vue
- Changement d'échelle
- Robustesse au flou
- Robustesse à la variation de l'intensité lumineuse
- Robustesse à la compression JPEG

Pour chacune des expériences, nous avons construit une base de 6 images, auxquelles nous avons d'une part appliqué nos algorithmes avec et sans prise en compte de la cohérence géométrique (mesure du recouvrement et mesure des nombre et pourcentage de correspondances correctes) et d'autre part les algorithmes des détecteurs disponibles sur le site de Mikolajczyk [Mikolajczyk, K. & al : 2005b] (mesure des nombre et pourcentage de correspondances correctes des détecteurs Harris-Affine, Hessien-Affine, MSER, EBR et IBR). Bien que les mesures ne soient pas déterminées exactement de la même manière, elles sont comparables puisqu'elles représentent la même grandeur, qui quantifie la capacité de la chaîne complète de traitement à extraire des régions de manière stable, quelles que soient les variations d'acquisition introduites.

5.5.1. Changement de point de vue



Figure 67 : Images utilisées pour l'évaluation de l'influence du changement de point de vue sur les performances du détecteur de régions curvilinéaires

La première évaluation de performance réalisée concerne le changement de point de vue. Nous avons donc constitué un ensemble d'images en faisant varier le point de vue avec les valeurs suivantes : $\{0^\circ, 15^\circ, 25^\circ, 35^\circ, 45^\circ \text{ et } 60^\circ\}$. Les clichés obtenus sont présentés à la Figure 67.

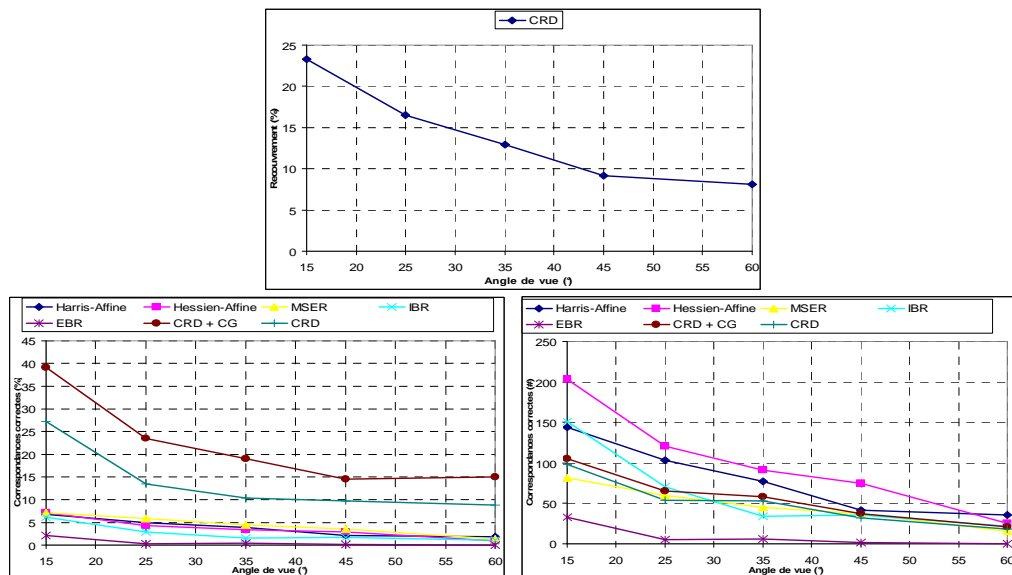


Figure 68 : Influence du changement de point de vue sur les performances du détecteur de régions curvilinéaires et des détecteurs standards

Sur cet ensemble d'images, le recouvrement des régions curvilinéaires détectées évolue de manière décroissante entre 23% et 8% tandis que le pourcentage de correspondances correctes varie entre 39% et 15% (27,2% et 8,8% sans prise en compte de la cohérence géométrique) (Figure 68). C'est un score nettement supérieur à celui des détecteurs standards qui pour la même expérience obtiennent, dans le meilleur des cas (MSER), un pourcentage de correspondance correcte compris entre 7% et 1%. Toutefois certaines méthodes permettent un nombre de correspondances correctes plus important. C'est le cas pour le détecteur Hessien-Affine, pour lequel ce nombre varie entre 200 et 25 régions contre 105 et 25 (98 et 18 sans la prise en compte de la cohérence géométrique) régions dans le cas du détecteur de régions curvilinéaires.

5.5.2. Changement d'échelle




Figure 69 : Images utilisées pour l'évaluation de l'influence du changement d'échelle sur les performances du détecteur de régions curvilinéaires

Dans un second temps, nous avons évalué l'influence du changement d'échelle sur les performances du détecteur de régions curvilinéaires. Comme pour le premier ensemble d'expérience, nous avons créé une base d'images en faisant varier le facteur d'échelle. Ce paramètre prend les valeurs suivantes : {1, 1.2, 1.35, 1.5, 1.95 et 2.11} (Figure 69).

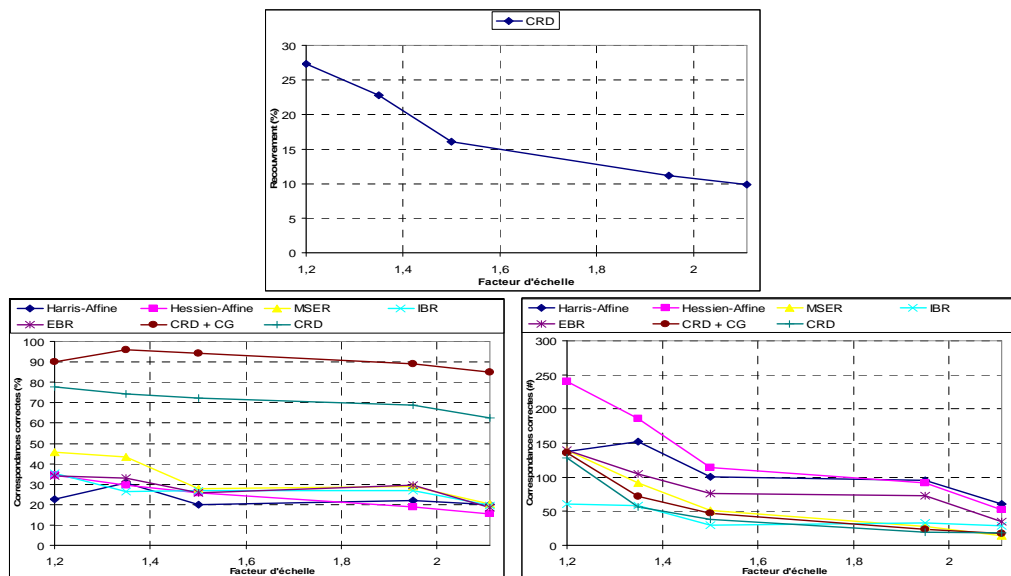


Figure 70 : Influence du changement d'échelle sur les performances du détecteur de régions curvilinéaires et des détecteurs standards

Le recouvrement des régions détectées par le CRD varie entre 27% et 10% (Figure 70). Le pourcentage de correspondances s'avère très élevé puisqu'il varie entre 96 et 88% (77% et 63% sans prise en compte de la cohérence géométrique). Ces résultats sont encore une fois meilleurs que ceux des détecteurs standards. Pour ces détecteurs, ce sont les « MSER » qui donnent un score de correspondances correctes le plus élevés avec un pourcentage compris entre 45% et 25%. Le nombre de correspondance correcte évolue entre 96 et 20 (98 et 18 sans prise en compte de la cohérence géométrique) dans le cas du détecteur de régions curvilinéaires et entre 245 et 50 pour le meilleur détecteur standard (Hessien-Affine).

5.5.3. Sensibilité au flou




Figure 71 : Images utilisées pour l'évaluation de l'influence du flou sur les performances du détecteur de régions curvilinéaires

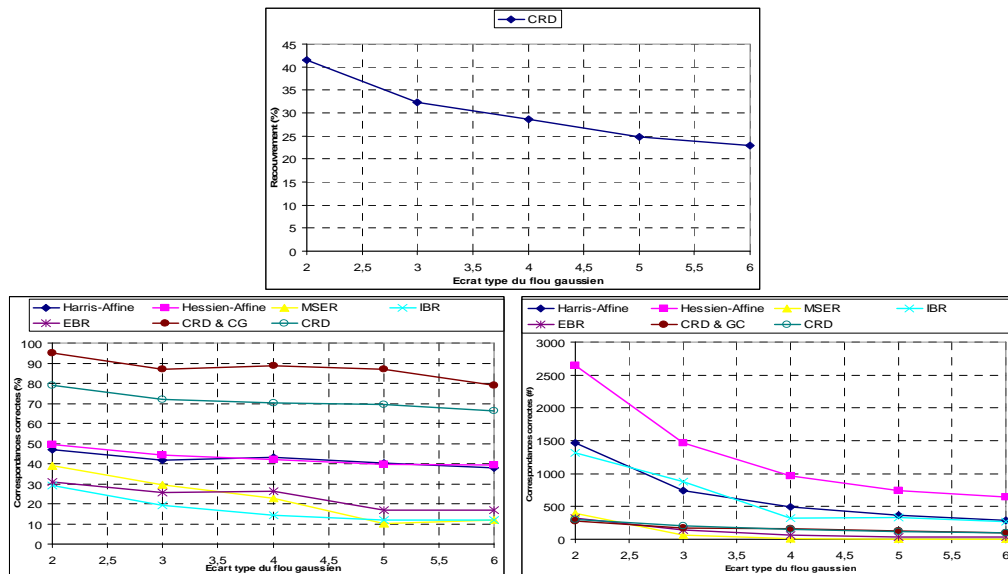


Figure 72 : Influence du flou sur les performances du CRD et des détecteurs standards

Dans un troisième temps, nous avons étudié l'influence du flou sur les performances de notre détecteur. Pour cela nous avons constitué une série de 6 images. Nous avons réalisé une convolution de chaque image avec une

gaussienne dont nous avons fait varier la valeur de l'écart-type. Cet écart-type prend les valeurs suivantes : $\{0,2,3,4,5,6\}$. Les images obtenues sont présentées à la Figure 71.

Sur cet ensemble d'images, le recouvrement (voir Figure 72) des régions trouvées par notre détecteur évolue entre 40% et 23%. Le pourcentage de correspondances correctes varie entre 95% et 78% (72% et 66% sans la prise en compte de la cohérence géométrique). Le nombre de correspondances correctes lui évolue entre 275 et 100 (301 et 93 sans la prise en compte de la cohérence géométrique).

Pour les mêmes données, les détecteurs standards présentent des résultats de mise en correspondances nettement inférieurs. En effet, le pourcentage de correspondances correctes (voir figure 29) varie dans le meilleur des cas entre 50% et 40%. Ce résultat est obtenu par le détecteur de points d'intérêt « Hessien-Affine ». On peut ajouter que le détecteur « Harris-Affine » obtient des performances quasi-similaires. Ces deux détecteurs, bien qu'ils présentent une sensibilité moins importante que le détecteur de régions curvilinéaires (décroissance de 10% pour le CRD et 17% pour Hessien-Affine) ont des pourcentages de correspondances correctes deux fois moins importants. Le détecteur apparaissant le plus sensible au flou sont les MSER qui présentent une décroissance de presque 30%. Les résultats obtenues par EBR et IBR sont très similaires et varient entre 30% et 15%.

5.5.4. Changement d'intensité d'éclairage




Figure 73 : Images utilisées pour évaluer l'influence du changement de d'éclaire sur les performances du détecteur de régions curvilinéaires

L'effet du changement d'intensité d'éclairage est étudié à l'aide de l'ensemble d'images présenté à la Figure 73. Cet ensemble d'image a été réalisé en faisant varier le temps d'intégration de l'appareil photo tout en maintenant l'ouverture du diaphragme constante. Les valeurs utilisées pour les temps d'intégration sont (en s) : $\{1/100, 1/160, 1/200, 1/300, 1/400, 1/640\}$.




Figure 74 : Influence de l'intensité lumineuse sur les performances du détecteur de régions curvilinéaires et des détecteurs standards

Les résultats de l'influence du changement d'éclairage sur les performances du détecteur de régions curvilinéaires sont présentés à la Figure 74. Le recouvrement du CRD décroît entre 27% et 8%. Les résultats de mise en correspondance sont très bons puisque pour tous les niveaux d'intensité lumineuse le pourcentage de correspondances correctes est supérieur à 60% (45% sans la prise en compte de la cohérence géométrique). Le nombre de correspondances exactes varie entre 192 et 60 (585 et 235 sans la prise en compte de la cohérence géométrique) régions détectées.

Sur ce même ensemble d'images, les détecteurs standards obtiennent un pourcentage de correspondances correctes nettement inférieur. Le détecteur présentant les meilleurs résultats sont les MSER dont le pourcentage de mise en correspondance correcte est en compris entre 45% et 20%. Cependant tous les détecteurs standards obtiennent un nombre de correspondances correctes supérieur au détecteur de régions curvilinéaires. Dans le pire des cas, pour le détecteur IBR, le nombre de régions varie entre 750 et 120.

5.5.5. Compression JPEG




Figure 75 : Images utilisées pour étudier l'influence de la compression JPEG sur les performances du détecteur de régions curvilinéaires




Figure 76 : Influence de la compression JPEG sur les performances du détecteur de régions curvilinéaires et des détecteurs standards

Afin d'étudier l'influence des artefacts créés par la compression JPEG, nous avons constitué l'ensemble d'images de test présenté à la Figure 75. Pour réaliser cette base d'images, nous avons fait varier le facteur de compression JPEG du logiciel de visualisation Irfanview [Skiljan, I. 2008]. Il faut noter que

nous avons choisi la scène originale de manière à ce qu'elle comporte une grande surface homogène (la porte du garage) et des zones comportant des détails de haute fréquence (les portails, les arbustes), afin d'observer les effets de la compression JPEG.

Les performances de notre détecteur sont présentées à la Figure 76, le recouvrement varie entre 90% et 63%. Le pourcentage de correspondances correctes est très élevé puisqu'il varie entre 98% et 83% (95% et 63% sans cohérence géométrique). Ce score est nettement supérieur aux deux meilleurs détecteurs standards, Harris-Affine et Hessien-Affine notamment pour les niveaux de compression élevés. Par exemple, pour un niveau de compression de 97%, le pourcentage de correspondances correctes de Hessien-Affine est de 70% alors qu'il est de 93% pour notre détecteur. Pour les autres détecteurs standards (IBR, EBR et MSER), les résultats sont très proches, le pourcentage de correspondance correct évoluant de manière décroissante entre 85% et 50%.

Concernant le nombre de correspondances correctes, notre détecteur, donne une valeur comprise entre 3200 et 1200 (2379 et 688 sans prise en compte de la cohérence géométrique) régions. Ce nombre est pratiquement comparable au score réalisé par le meilleur détecteur Hessien-Affine qui recense entre 3200 et 2200 régions.

5.6. Estimation d'homographies

5.6.1. Méthodologie

A partir des deux outils précédemment développés, le détecteur de régions curvilinéaires et le descripteur « curvilinear region shape descriptor », nous pouvons déterminer automatiquement l'homographie reliant un couple d'image. Cette homographie est définie par une matrice qui permet de calculer les coordonnées transformée d'un point d'une image, dans l'autre image, sous réserve que la scène soit plane ou quasi-plane.

Pour estimer les coefficients de cette matrice à l'aide de la méthode d'estimation automatique de Zisserman [Hartley, R. I. & al : 2004], nous

avons besoin d'un minimum de quatre points dans chaque image, les points se correspondant deux à deux.

Pour déterminer ces points, il est courant d'utiliser un détecteur de région suivi d'un descripteur, qui permet de réaliser la mise en correspondance de manière automatique. C'est cette méthode que nous avons utilisée, en appliquant le CRD sur les deux images étudiées. Pour chacune des régions, nous appliquons le descripteur CRSD. Les tentatives de correspondance sont ensuite formées en utilisant une stratégie de vérification croisée, dans l'optique de réduire le nombre de faux appariements.




Figure 77 : Illustration de la stratégie de mise en correspondance

La méthode de mise en correspondance par vérification croisée commence par mettre en correspondance les régions de I_1 avec celles de I_2 en utilisant l'approche du plus proche voisin dans l'espace des descripteurs. On échange ensuite le rôle des images I_1 et I_2 . Les couples de points correspondant retenus sont ceux qui ont été mutuellement sélectionnés. Ce processus est illustré par la Figure 77

Enfin à partir des tentatives de correspondances formées, on applique une méthode couramment utilisée permettant l'estimation d'un modèle en présence d'échantillons incorrects au sein de l'ensemble des échantillons candidats: RANSAC (RANdom SAMple Consensus) [Fischler, M. A. & al : 1981a]. Dans notre cas le modèle recherché est donc une homographie.

L'ensemble du processus d'estimation de l'homographie est présenté à la Figure 78.

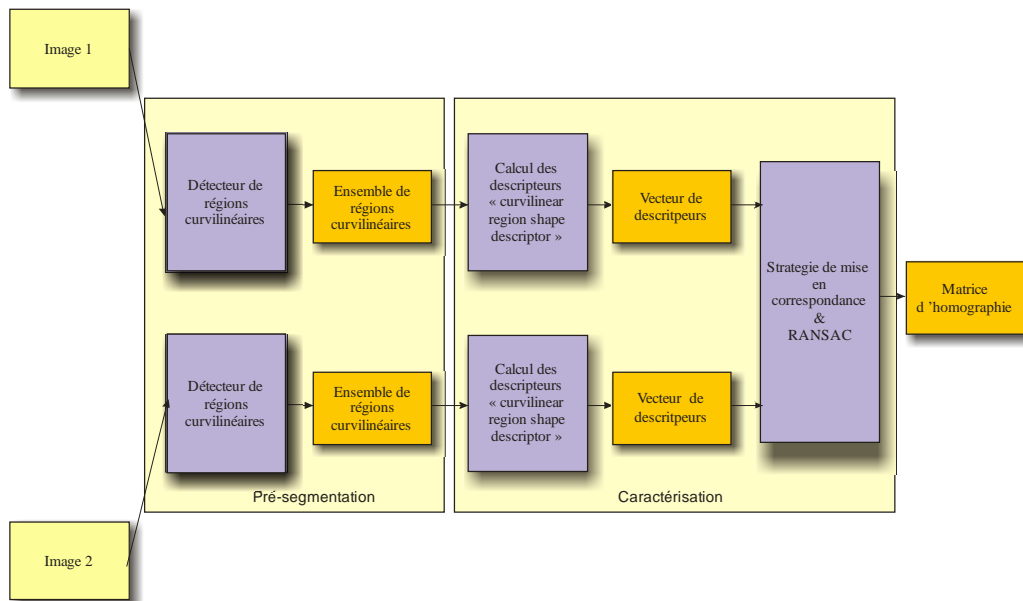


Figure 78 : Principe de l'estimation automatique d'homographie

5.6.2. Résultats

La Figure 79 présente les résultats de l'estimation automatique de l'homographie. Nous avons fait apparaître en vert les correspondances correctes vérifiant l'homographie (inliers) estimée.

| Description des Scènes | Câble Sur Sol (a) | Câble fond différents (b) | Câble fond texturé : (c) | Grille (d) | Portail (e) | Graffiti (f) | Porte (g) | Mur (h) | Panorama (i) |
|--|-------------------|---------------------------|--------------------------|------------|-------------|--------------|-----------|-----------|--------------|
| Inliers (#) pour le CRD | 60 | 80 | 230 | 95 | 89 | 51 | 56 | 65 | 12 |
| Inliers pour le CRD(%) | 35.1 | 27.7 | 40.4 | 12 | 15.9 | 12.4 | 13.6 | 40.4 | 20.7 |
| Inliers (#) avec WBM-MSER ⁴ | 326 | 10 | 96 | 94 | 9 | 175 | 20 | 65 | 12 |
| Inliers (%) avec WBM-MSER | 40.4 | 100 | 87.27 | 28.1 | 18.75 | 72.89 | 20 | 92 | 13 |

Tableau 10 : Résultats de l'estimation d'homographies pour la méthode utilisation le CRD et le WBS-MSER

Les résultats présentés au Tableau 10 ont été obtenus dans le premier cas en utilisant notre méthode et dans le second cas en utilisant l'application de mise en correspondance : « wide baseline matching » [Matas, J. & al : 2002] développée par l'équipe du CMP. Ces résultats tendent à montrer que notre application donne de meilleurs résultats, en termes de nombre d'inliers, lorsque la paire d'images contient un nombre prépondérant de structures curvilinéaires. C'est le cas pour la paire contenant le portail blanc (e) et le câble avec des fonds différents (b) ou encore pour la porte (g). Dans les autres cas, les résultats sont similaires.

Cependant lorsque la scène ne contient pas de région curvilinéaire, comme par exemple la scène avec des objets courant (i), l'estimation d'homographie s'avère impossible.

⁴ WBS-MSER : application d'estimation d'homographie automatique wide baseline matching utilisant les MSER disponible à l'adresse suivante: <http://cmp.felk.cvut.cz/~wbsdemo/demo/wbsmain.php>

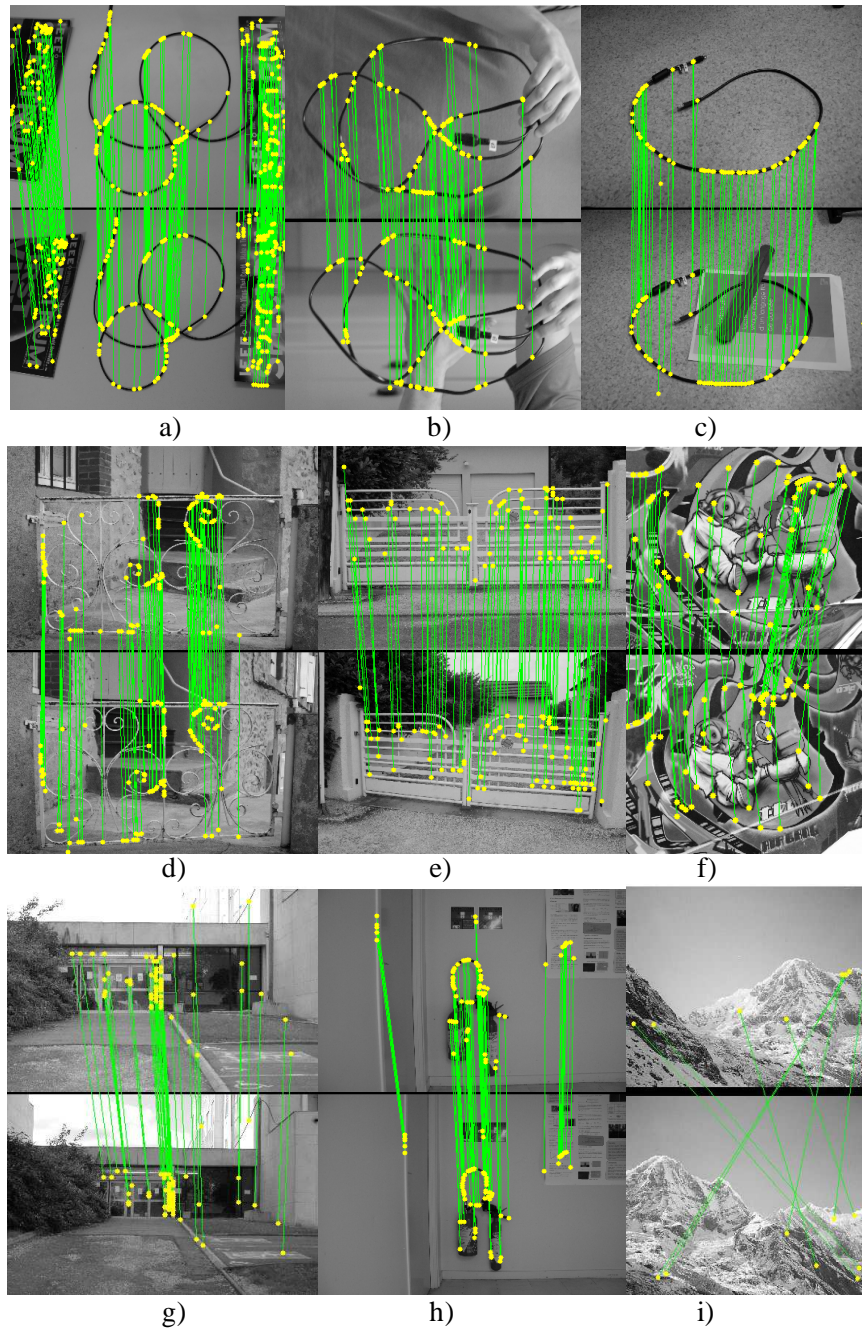


Figure 79 : Illustration de l'estimation automatique d'homographies (les inliers apparaissent en couleur)

5.7. Discussion des résultats

Nous avons présenté dans cette section des résultats quantitatifs des performances de mise en correspondance du détecteur CRD et du descripteur CRSD. Les résultats obtenus tendent à montrer que les régions détectées par le CRD et décrites par le CRSD sont répétables et très robustes malgré des changements importants de condition d'acquisition, et donnent des résultats de mise en correspondance souvent meilleurs que les détecteurs généralistes.

De plus, on peut affirmer que la prise en compte de la cohérence géométrique permet d'augmenter le pourcentage de correspondances correctes d'environ 20%. Il faut aussi noter que même si la cohérence géométrique permet d'augmenter le pourcentage de correspondances correctes, elle a aussi pour effet de diminuer dans certains cas le nombre absolu de ces correspondances.

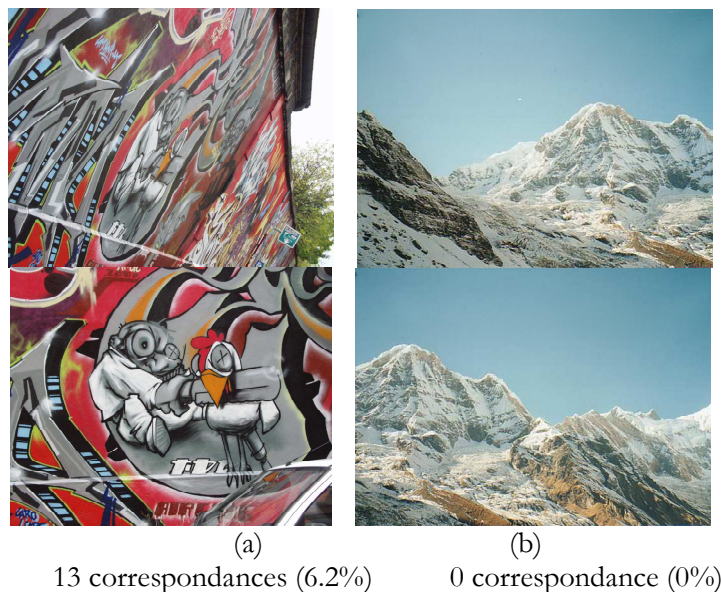


Figure 80 : Exemple de paires d'images pour lesquelles le CRD fonctionne de façon médiocre (a) ou ne fonctionne pas (b)

Il faut prendre en compte le fait que les bases d'images que nous avons constituées contiennent des régions curvilinéaires en grande quantité. Le

CDR ne donnera pas forcément les meilleurs résultats dans nombre de cas où les régions curvilinéaires sont peu présentes.

Les exemples présentés à la Figure 80 illustrent bien cette limite, lorsque les images contiennent peu (Figure 80) ou pas du tout (Figure 80-b) de régions curvilinéaires. Dans ces deux cas, les MSER, par exemple, donnent d'excellents résultats (respectivement 25% et 59%).

La principale conclusion des expériences précédentes est donc que les régions curvilinéaires peuvent apporter une information supplémentaire importante et stable pour les opérations de mise en correspondance, bien entendu lorsque les images contiennent un nombre significatif de ces régions. Ce résultat était attendu, puisque le CDR est un détecteur spécialisé. Il est à noter que les détecteurs généralistes détectent mal ces régions, ce qui conforte l'importance du détecteur CRD. Il pourra être judicieux de le combiner avec l'un ou plusieurs des autres détecteurs afin d'augmenter encore les performances globales.

Conclusion

Dans ce mémoire, nous avons abordé la détection, la caractérisation et l'étude de l'apport des régions curvilinéaires dans les opérations de mise en correspondance.

Après avoir réalisé un état de l'art des techniques de détection de points et régions d'intérêt ainsi que des méthodes d'extraction de régions curvilinéaires, nous avons mis évidence les lacunes de certains détecteurs parfois trop spécialisés. Ainsi les méthodes d'extraction de régions curvilinéaires existantes ne prennent pas toujours en compte les informations de variation de la courbure locale et de variation de largeur sur l'ensemble de la forme, et prennent rarement en compte l'aspect texturé des images.

Pour ces raisons, nous avons introduit un modèle, inspiré pour partie des méthodes existantes, permettant la détection de régions curvilinéaires d'une manière la plus stable possible. Ce modèle comprend à la fois un détecteur de section ainsi qu'un processus d'extraction complet de régions curvilinéaires mettant en jeu des contraintes sur la largeur et la courbure de la forme, ainsi que sur les textures internes et externes.

L'état de l'art des descripteurs de régions locales nous a ensuite montré que les méthodes actuelles ne sont pas réellement adaptées à la caractérisation de régions curvilinéaires. Par conséquent, nous avons proposé, en collaboration avec le CMP (Prague) le descripteur CRSD qui permet de caractériser un point de l'axe d'une structure curvilinéaire par la distribution spatiale de points axiaux de régions curvilinéaires présentant les mêmes caractéristiques de courbure et largeur dans un voisinage du point étudié.

Afin de valider expérimentalement le modèle et le détecteur que nous avons mis au point, nous avons étudié ses performances de façon approfondie, tout d'abord au niveau du détecteur de section, puis au niveau du détecteur complet, finalement associé au CRSD. La validation a été réalisée de manière qualitative et quantitative pour la phase de segmentation, ce qui nous a permis de positionner le CRD par rapport à quelques détecteurs existants, puis encore quantitative pour la répétabilité complète, en suivant un protocole

aujourd'hui quasiment standardisé par Mikolajczyk pour l'évaluation de ce type d'opérateur. Pour déterminer les performances de notre détecteur nous avons introduit une mesure de « recouvrement » qui quantifie les qualités de pré-segmentation du détecteur de régions curvilinéaires et donne une indication sur les performances potentielles de mise en correspondance. En plus de ce critère, nous avons évalué les qualités de mise en correspondance en utilisant le détecteur CRD, le descripteur spécifique associé, et une méthode mise en correspondance utilisant une phase d'analyse de la cohérence géométrique

Notre détecteur s'est révélé robuste aux différentes variations d'acquisition ou de dégradation du signal, donnant des résultats de mise en correspondance supérieurs à ceux obtenus par la méthodologie de Mikolajczyk.

Nous avons également présenté des résultats préliminaires de détection de l'aorte sur des images IRM. Ces résultats permettent d'affirmer qu'il est possible de détecter l'aorte dans sa partie descendante. Cependant afin d'augmenter la robustesse de détection (précision de mesure de la largeur), il semble nécessaire d'effectuer une étude complémentaire permettant l'apprentissage des paramètres optimaux du modèle pour cette application. Cette dernière, pour être opérationnelle, devra également comporter une détection de l'aorte ascendante. Malheureusement cette partie ne répond pas ou peu à notre modèle. Il sera donc nécessaire de déterminer quelle méthode semble appropriée pour réaliser cette détection.

Enfin nous avons proposé l'application de l'ensemble : -détecteur de régions curvilinéaires, descripteur de régions curvilinéaires et méthodologie de mise en correspondance – à l'estimation automatique d'homographies. Les résultats sont encourageants et permettent d'envisager plusieurs extensions de ces travaux.

Dans un premier temps, des améliorations de certaines phases du CRD sont envisageables. Il serait intéressant d'étudier l'apport d'autres méthodes de détection de contours pour remplacer le filtre de Petrou-Kittler utilisé pour créer l'ensemble restreint des pixels candidats pour appartenir à une région curvilinéaire. Ainsi, il serait par exemple possible d'utiliser le résultat de l'algorithme de la ligne de partage des eaux, calculé soit sur une image du gradient soit sur une image de courbure.

Dans un second temps, la répétabilité et les résultats de mise en correspondance étant satisfaisants, il sera possible d'apparier les régions curvilinéaires contenues dans deux images provenant d'une même scène dans des conditions d'acquisition différentes. Comme pour les autres détecteurs, les régions curvilinéaires pourront être utilisées dans un contexte de reconnaissance de formes par approche locale.

Cependant dans ce genre d'application, plutôt que remplacer purement et simplement les détecteurs « standards » par le CDR, il conviendra certainement de les combiner (Figure 81). En effet dans les cas où l'objet à reconnaître contient peu de régions curvilinéaires, on peut facilement imaginer que les performances de la méthode seraient médiocres.

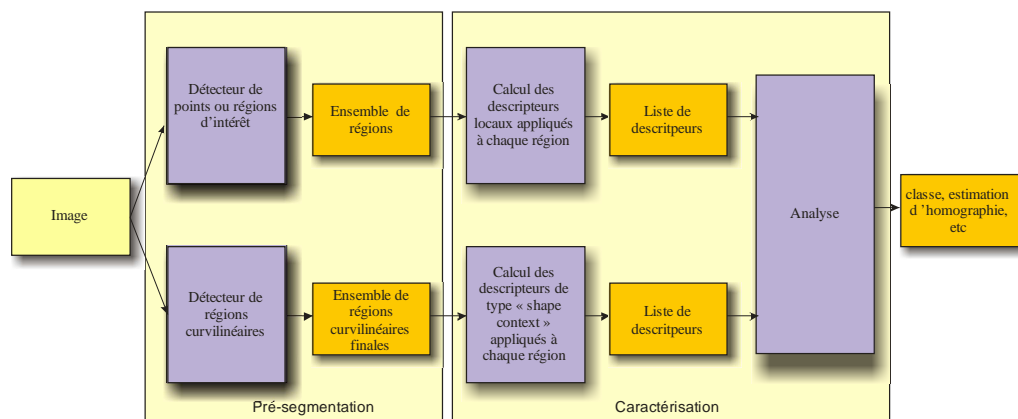


Figure 81 : Illustration de la combinaison d'information provenant des détecteurs "standard" et du détecteur de régions curvilinéaires

Pour réaliser cette combinaison, on peut envisager deux méthodologies.

La première méthode consiste à associer manuellement au CRD, les détecteurs de « régions standards ». Il faut toutefois prendre soin de sélectionner dans cette famille de détecteurs ceux dont les résultats de détection sont les moins redondants avec ceux du CRD. Il faut, par exemple, éviter d'associer le CRD et les MSERs puisque certaines régions curvilinéaires sont aussi détectables par les MSERs. Toutefois, l'association du détecteur Hessien-Affine et CRD semble être une bonne solution. En effet la méthode de détection du Hessien-Affine pénalise fortement les structures longues et courbes alors que celles-ci sont détectées par le CRD.

La seconde méthode consisterait à rassembler tous les résultats des détecteurs présentés ici au sein d'un unique algorithme d'apprentissage (de type boosting), capable de sélectionner les paramètres discriminants. Une méthode très similaire est décrite par Opelt dans [Opelt, A. & al : 2006].

Annexe 1 : Evaluation de l'influence des paramètres du CRD

Les tableaux suivants regroupent les résultats de l'étude de l'influence des différents paramètres du détecteur de régions curvilinéaires.

Le premier tableau présente les performances de pré-segmentation. Les paires d'images sont classées par difficulté croissante de gauche à droite. Les résultats des différentes configurations sont classés suivant les lignes par performances moyennes et selon l'ordre décroissant. Enfin la couleur représente le pourcentage par rapport au maximum de la colonne. La légende est la suivante :

- vert : résultat supérieur à 50% du maximum (de la colonne)
- jaune : résultat compris entre 50% et 25% du maximum
- rouge : résultat compris entre 25% et 10% du maximum
- bleu : résultat compris entre 10% et 5% du maximum
- gris : résultat inférieur à 5% du maximum

Le second tableau représente les performances de mise en correspondance. Les pourcentages et nombres de correspondances correctes pour les quinze meilleures configurations apparaissent.

L'organisation du tableau est la même que précédemment.

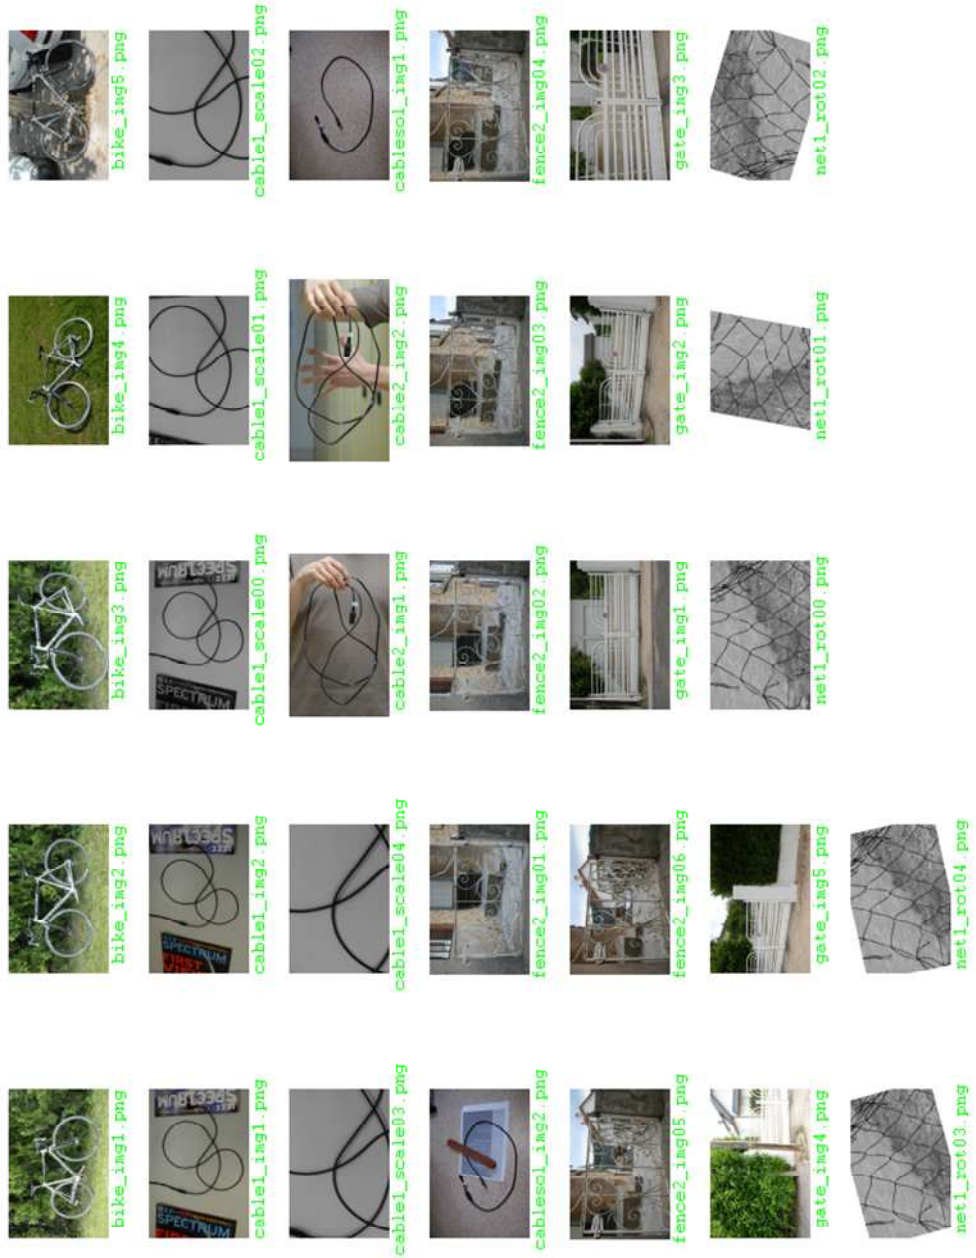
Enfin nous présentons toutes les images utilisées pour cette expérience.

Résultats de recouvrement (%)

| | cab1e1 scale 00 vs. 01 | cab1e1 scale 02 | cab1e1 scale 03 | cab1e1 scale 04 | net1 rot 00 vs. 01 | net1 rot 02 | net1 rot 03 | net1 rot 04 | cab1e1 scale 00 vs. 01 | cab1e1 scale 02 | cab1e1 scale 03 | cab1e1 scale 04 | net1 rot 00 vs. 01 | net1 rot 02 | net1 rot 03 | net1 rot 04 | cab1e1 scale 00 vs. 01 | cab1e1 scale 02 | cab1e1 scale 03 | cab1e1 scale 04 | net1 rot 00 vs. 01 | net1 rot 02 | net1 rot 03 | net1 rot 04 | gate 1 vs. 2 | gate 1 vs. 3 | gate 1 vs. 4 | gate 1 vs. 5 | gate 1 vs. 6 | cab1e2 1 vs. 2 | cab1e2 1 vs. 3 | cab1e2 1 vs. 4 | cab1e2 1 vs. 5 | cab1e2 1 vs. 6 | fencez 01 vs. 02 | fencez 01 vs. 03 | bike 1 vs. 2 | bike 1 vs. 3 | bike 1 vs. 4 | bike 1 vs. 5 | Cfencez 1 vs. 2 | Cfencez 1 vs. 3 | Cfencez 1 vs. 4 | Cfencez 1 vs. 5 | Cfencez 1 vs. 6 |
|---------------|------------------------|-----------------|-----------------|-----------------|--------------------|-------------|-------------|-------------|------------------------|-----------------|-----------------|-----------------|--------------------|-------------|-------------|-------------|------------------------|-----------------|-----------------|-----------------|--------------------|-------------|-------------|-------------|--------------|--------------|--------------|--------------|--------------|----------------|----------------|----------------|----------------|----------------|------------------|------------------|--------------|--------------|--------------|--------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 07- F4WV0.3Ta | 49.052 | 55.871 | 51.262 | 59.444 | 41.338 | 39.433 | 45.409 | 48.196 | 9.456 | 18.430 | 28.783 | 13.922 | 14.716 | 24.961 | 18.775 | 23.286 | 16.548 | 4.476 | 6.120 | 2.576 | 4.152 | 4.461 | 0.766 | 3.437 | 1.391 | 1.649 | | | | | | | | | | | | | | | | | | | |
| 55- F4WV0.3Ta | 49.052 | 55.871 | 51.262 | 59.444 | 41.339 | 39.433 | 45.409 | 48.196 | 11.741 | 16.151 | 26.032 | 13.735 | 15.406 | 24.700 | 13.887 | 24.980 | 17.638 | 3.576 | 5.311 | 2.485 | 3.880 | 3.758 | 0.550 | 3.301 | 1.116 | 1.990 | | | | | | | | | | | | | | | | | | | |
| 11- F4WV0.5Ta | 50.859 | 56.286 | 52.583 | 56.524 | 40.819 | 38.276 | 45.034 | 46.346 | 10.549 | 16.290 | 24.411 | 12.486 | 13.270 | 22.865 | 15.645 | 22.289 | 16.242 | 3.007 | 3.966 | 2.443 | 3.680 | 4.629 | 1.895 | 2.569 | 1.650 | 2.520 | | | | | | | | | | | | | | | | | | | |
| 59- F4WV0.5Ta | 50.859 | 56.286 | 52.583 | 56.524 | 40.819 | 38.276 | 45.034 | 46.346 | 11.022 | 15.714 | 24.662 | 12.674 | 14.970 | 23.602 | 11.166 | 23.086 | 16.102 | 3.824 | 4.545 | 2.362 | 3.012 | 4.060 | 1.875 | 2.650 | 1.388 | 2.891 | | | | | | | | | | | | | | | | | | | |
| 15- F4WV0.7Ta | 51.681 | 53.611 | 53.202 | 57.925 | 40.441 | 36.360 | 43.959 | 44.075 | 9.693 | 15.938 | 23.997 | 12.321 | 13.626 | 21.510 | 11.200 | 22.111 | 15.336 | 3.111 | 4.484 | 2.496 | 4.459 | 4.988 | 3.256 | 2.569 | 1.977 | 3.314 | | | | | | | | | | | | | | | | | | | |
| 63- F4WV0.7Ta | 51.681 | 53.611 | 53.202 | 57.925 | 40.441 | 36.360 | 43.959 | 44.075 | 9.693 | 15.938 | 23.997 | 12.321 | 13.626 | 21.510 | 11.200 | 22.111 | 16.870 | 3.282 | 4.562 | 2.395 | 3.977 | 4.481 | 2.862 | 2.552 | 1.740 | 3.756 | | | | | | | | | | | | | | | | | | | |
| 06- F4WV0.3Ta | 46.369 | 42.260 | 34.711 | 37.255 | 40.465 | 38.818 | 45.245 | 47.019 | 9.837 | 16.238 | 26.295 | 14.318 | 14.605 | 24.382 | 17.041 | 22.964 | 16.389 | 4.453 | 5.548 | 2.501 | 3.953 | 4.404 | 0.398 | 3.196 | 1.887 | 1.680 | | | | | | | | | | | | | | | | | | | |
| 71- F8WV0.3Ta | 40.730 | 35.656 | 28.269 | 24.916 | 46.525 | 37.196 | 44.840 | 47.788 | 13.561 | 23.411 | 31.060 | 20.127 | 11.580 | 23.461 | 17.602 | 15.644 | 11.328 | 6.214 | 10.278 | 5.622 | 5.631 | 8.697 | 1.734 | 4.647 | 2.359 | 3.173 | | | | | | | | | | | | | | | | | | | |
| 10- F4WV0.5Ta | 46.496 | 46.466 | 41.699 | 44.310 | 40.116 | 37.821 | 44.202 | 44.841 | 10.230 | 14.833 | 23.574 | 12.206 | 13.236 | 23.165 | 13.744 | 21.936 | 16.124 | 3.097 | 3.980 | 2.485 | 3.575 | 4.401 | 1.950 | 2.351 | 1.740 | 2.654 | | | | | | | | | | | | | | | | | | | |
| 14- F4WV0.7Ta | 47.531 | 45.736 | 42.174 | 45.486 | 39.555 | 35.144 | 42.911 | 43.249 | 9.033 | 15.394 | 22.895 | 11.617 | 12.029 | 21.956 | 12.646 | 20.565 | 15.092 | 3.031 | 4.585 | 2.448 | 4.211 | 5.121 | 3.034 | 2.561 | 1.921 | 3.469 | | | | | | | | | | | | | | | | | | | |
| 75- F8WV0.5Ta | 37.389 | 35.019 | 27.840 | 24.651 | 45.706 | 37.878 | 45.756 | 46.860 | 14.885 | 24.460 | 29.548 | 19.140 | 12.003 | 23.763 | 14.585 | 15.503 | 12.334 | 4.567 | 7.499 | 3.755 | 4.448 | 7.750 | 2.675 | 4.013 | 2.186 | 3.942 | | | | | | | | | | | | | | | | | | | |
| 79- F8WV0.7Ta | 36.503 | 34.145 | 26.925 | 23.016 | 43.790 | 37.373 | 43.910 | 47.448 | 15.050 | 23.871 | 27.557 | 18.274 | 11.057 | 23.428 | 13.639 | 15.963 | 11.795 | 4.748 | 6.851 | 4.066 | 5.134 | 7.003 | 3.095 | 3.835 | 3.011 | 4.509 | | | | | | | | | | | | | | | | | | | |
| 23- F8WV0.3Ta | 40.730 | 35.656 | 28.269 | 24.916 | 46.525 | 37.196 | 44.840 | 47.788 | 13.878 | 18.362 | 28.598 | 18.431 | 10.848 | 24.198 | 19.660 | 0.000 | 0.000 | 5.676 | 6.433 | 5.111 | 6.066 | 8.716 | 2.381 | 3.971 | 2.184 | 2.998 | | | | | | | | | | | | | | | | | | | |
| 51- F4WV0.1Ta | 49.504 | 38.733 | 33.207 | 30.185 | 40.329 | 35.974 | 38.417 | 39.960 | 9.694 | 20.587 | 28.995 | 13.162 | 14.850 | 26.278 | 27.640 | 0.000 | 0.000 | 5.160 | 5.806 | 4.067 | 7.027 | 7.051 | 0.000 | 6.584 | 0.215 | 0.290 | | | | | | | | | | | | | | | | | | | |
| 58- F4WV0.5Ta | 46.496 | 46.466 | 41.699 | 44.310 | 40.116 | 37.821 | 44.202 | 44.841 | 10.906 | 14.230 | 23.635 | 12.814 | 14.378 | 23.343 | 10.399 | 0.000 | 0.000 | 3.387 | 4.361 | 2.482 | 2.851 | 4.069 | 2.043 | 2.653 | 1.241 | 2.721 | | | | | | | | | | | | | | | | | | | |
| 70- F8WV0.3Ta | 38.022 | 33.167 | 26.015 | 23.725 | 46.139 | 36.698 | 44.538 | 47.764 | 13.389 | 21.503 | 30.600 | 19.915 | 11.001 | 23.231 | 16.893 | 0.000 | 0.000 | 6.473 | 10.543 | 5.137 | 6.050 | 8.210 | 1.820 | 4.287 | 1.873 | 2.800 | | | | | | | | | | | | | | | | | | | |
| 54- F4WV0.3Ta | 46.369 | 42.260 | 34.711 | 37.255 | 40.465 | 38.818 | 45.245 | 47.019 | 11.592 | 16.176 | 25.643 | 13.455 | 15.496 | 24.797 | 11.823 | 0.000 | 0.000 | 3.847 | 5.140 | 2.455 | 3.766 | 3.946 | 0.398 | 3.348 | 0.886 | 1.703 | | | | | | | | | | | | | | | | | | | |
| 62- F4WV0.7Ta | 47.531 | 45.736 | 42.174 | 45.486 | 39.555 | 35.144 | 42.911 | 43.249 | 9.699 | 14.133 | 22.155 | 11.758 | 13.582 | 21.041 | 10.901 | 0.000 | 0.000 | 3.299 | 4.391 | 2.438 | 3.893 | 4.967 | 2.835 | 2.492 | 1.732 | 3.833 | | | | | | | | | | | | | | | | | | | |
| 69- F8WV0.3Ta | 37.431 | 31.635 | 24.476 | 20.855 | 46.003 | 36.623 | 44.508 | 47.544 | 13.579 | 22.211 | 30.113 | 19.656 | 10.844 | 22.972 | 18.101 | 0.000 | 0.000 | 6.555 | 10.257 | 5.093 | 6.031 | 8.026 | 1.660 | 4.299 | 1.823 | 2.732 | | | | | | | | | | | | | | | | | | | |
| 03- F4WV0.1Ta | 49.504 | 38.733 | 33.207 | 30.185 | 40.329 | 35.974 | 38.417 | 39.960 | 9.469 | 21.031 | 24.849 | 13.276 | 14.092 | 24.213 | 23.548 | 0.000 | 0.000 | 4.639 | 7.128 | 2.895 | 4.340 | 7.759 | 0.000 | 5.851 | 1.238 | 1.783 | | | | | | | | | | | | | | | | | | | |
| 27- F8WV0.5Ta | 37.389 | 35.019 | 27.840 | 24.651 | 45.706 | 37.878 | 45.756 | 46.860 | 13.464 | 18.615 | 27.734 | 17.072 | 11.002 | 23.268 | 16.867 | 0.000 | 0.000 | 4.887 | 5.636 | 4.157 | 4.702 | 6.835 | 2.727 | 3.922 | 2.523 | 3.544 | | | | | | | | | | | | | | | | | | | |
| 22- F8WV0.3Ta | 38.022 | 33.167 | 26.015 | 23.725 | 46.139 | 36.698 | 44.538 | 47.764 | 13.610 | 17.597 | 27.904 | 17.924 | 10.196 | 23.394 | 19.334 | 0.000 | 0.000 | 5.641 | 6.346 | 5.113 | 5.587 | 7.604 | 1.928 | 3.654 | 2.333 | 3.030 | | | | | | | | | | | | | | | | | | | |
| 74- F8WV0.5Ta | 35.221 | 32.790 | 25.068 | 23.625 | 45.064 | 37.583 | 44.826 | 47.026 | 15.002 | 23.291 | 28.427 | 18.927 | 11.524 | 23.424 | 14.016 | 0.000 | 0.000 | 3.126 | 3.943 | 2.456 | 3.635 | 4.398 | 2.017 | 2.303 | 1.922 | 2.527 | | | | | | | | | | | | | | | | | | | |
| 09- F4WV0.5Ta | 44.566 | 44.115 | 35.395 | 34.896 | 39.864 | 37.404 | 44.234 | 44.876 | 10.267 | 14.609 | 23.833 | 12.307 | 13.206 | 23.417 | 13.030 | 0.000 | 0.000 | 5.103 | 7.489 | 3.976 | 4.655 | 6.245 | 2.380 | 3.796 | 2.236 | 4.427 | | | | | | | | | | | | | | | | | | | |
| 73- F8WV0.5Ta | 34.611 | 31.278 | 23.459 | 20.765 | 45.233 | 37.290 | 44.961 | 47.125 | 15.094 | 23.678 | 28.210 | 18.851 | 11.783 | 23.528 | 15.630 | 0.000 | 0.000 | 4.978 | 5.425 | 3.592 | 5.017 | 6.894 | 3.464 | 3.208 | 3.275 | 4.122 | | | | | | | | | | | | | | | | | | | |
| 31- F8WV0.7Ta | 36.503 | 34.145 | 26.925 | 23.016 | 43.790 | 37.373 | 43.910 | 47.448 | 12.752 | 22.387 | 26.657 | 16.802 | 8.115 | 22.911 | 19.417 | 0.000 | 0.000 | 4.378 | 5.425 | 3.592 | 5.017 | 6.894 | 3.464 | 3.208 | 3.275 | 4.122 | | | | | | | | | | | | | | | | | | | |
| 05- F4WV0.3Ta | 43.273 | 38.541 | 29.055 | 29.346 | 40.582 | 38.919 | 45.044 | 47.013 | 9.730 | 16.354 | 26.041 | 14.246 | 14.769 | 24.157 | 16.378 | 0.000 | 0.000 | 4.427 | 5.504 | 2.518 | 3.916 | 4.275 | 0.408 | 3.217 | 1.878 | 1.762 | | | | | | | | | | | | | | | | | | | |
| 21- F8WV0.3Ta | 37.431 | 31.635 | 24.476 | 20.855 | 46.003 | 36.623 | 44.508 | 47.544 | 13.635 | 17.654 | 28.188 | 17.758 | 10.228 | 23.535 | 18.890 | 0.000 | 0.000 | 5.693 | 6.283 | 5.141 | 5.527 | 8.310 | 2.017 | 3.667 | 2.341 | 3.050 | | | | | | | | | | | | | | | | | | | |
| 57- F4WV0.5Ta | 44.566 | 44.115 | 35.395 | 34.896 | 39.864 | 37.404 | 44.234 | 44.876 | 10.960 | 13.990 | 23.296 | 12.716 | 14.347 | 23.015 | 11.150 | 0.000 | 0.000 | 3.819 | 4.487 | 2.543 | 2.741 | 4.064 | 2.030 | 2.667 | 1.234 | 2.813 | | | | | | | | | | | | | | | | | | | |
| 21- F8WV0.3Ta | 37.431 | 31.635 | 24.476 | 20.855 | 46.003 | 36.623 | 44.508 | 47.544 | 11.662 | 16.271 | 25.799 | 13.263 | 15.614 | 24.795 | 12.879 | 0.000 | 0.000 | 4.378 | 5.425 | 3.592 | 5.017 | 6.894 | 3.464 | 3.208 | 3.275 | 4.122 | | | | | | | | | | | | | | | | | | | |
| 53- F4WV0.3Ta | 43.273 | 38.541 | 29.055 | 29.346 | 40.582 | 38.919 | 45.044 | 47.013 | 9.730 | 16.354 | 26.041 | 14.246 | 14.769 | 24.157 | 16.378 | 0.000 | 0.000 | 4.427 | 5.504 | 2.518 | 3.916 | 4.275 | 0.408 | 3.217 | 1.878 | 1.762 | | | | | | | | | | | | | | | | | | | |
| 50- F4WV0.1Ta | 46.647 | 32.449 | 26.650 | 23.415 | 40.314 | 35.475 | 38.040 | 40.311 | 9.772 | 20.544 | 25.083 | 13.704 | 15.416 | 26.628 | 25.627 | 0.000 | 0.000 | 5.624 | 6.035 | 4.546 | 6.989 | 5.886 | 0.000 | 5.246 | 0.189 | 0.631 | | | | | | | | | | | | | | | | | | | |
| 78- F8WV0.7Ta | 34.765 | 31.873 | 24.045 | 22.046 | 42.150 | 36.298 | 43.952 | 46.849 | 14.778 | 22.497 | 25.506 | 17.810 | 10.702 | 23.268 | 13.231 | 0.000 | 0.000 | 5.066 | 7.102 | 4.265 | 5.133 | 6.679 | 3.056 | 3.842 | 3.035 | 4.947 | | | | | | | | | | | | | | | | | | | |
| 13- F4WV0.7Ta | 44.790 | 42.002 | 35.694 | 35.476 | 39.431 | 35.272 | 42.686 | 42.894 | 8.990 | 15.091 | 22.543 | 11.389 | 12.217 | 21.684 | 11.958 | 0.000 | 0.000 | 3.046 | 4.511 | 2.413 | 4.288 | 5.208 | 2.917 | 2.519 | 1.943 | 3.453 | | | | | | | | | | | | | | | | | | | |
| 26- F8WV0.5Ta | 35.221 | 32.790 | 25.068 | 23.625 | 45.064 | 37.583 | 44.826 | 47.026 | 13.096 | 17.724 | 28.179 | 16.614 | 9.734 | 22.818 | 16.171 | 0.000 | 0.000 | 4.632 | 6.254 | 4.081 | 4.813 | 6.371 | 2.735 | 3.272 | 2.785 | 3.651 | | | | | | | | | | | | | | | | | | | |

| | | | | | | | | | | | | | | | | | | | | | | | | | | |
|----------------|--------|--------|-------|-------|--------|--------|--------|--------|--------|--------|--------|-------|--------|--------|--------|-------|-------|--------|--------|-------|--------|-------|-------|-------|-------|-------|
| 37- F16WV0.37c | 9.625 | 9.326 | 5.474 | 2.049 | 48.032 | 36.490 | 41.137 | 44.176 | 21.106 | 30.886 | 22.696 | 5.880 | 8.952 | 15.672 | 31.131 | 0.000 | 0.000 | 12.036 | 14.300 | 7.988 | 11.482 | 5.413 | 3.184 | 0.916 | 0.941 | 4.620 |
| 95- F16WV0.77a | 11.700 | 10.081 | 5.236 | 1.884 | 46.084 | 36.171 | 41.364 | 42.877 | 18.191 | 26.154 | 19.497 | 6.960 | 9.219 | 16.167 | 30.309 | 0.000 | 0.000 | 10.494 | 14.755 | 7.596 | 8.923 | 8.231 | 7.332 | 0.756 | 3.432 | 8.748 |
| 90- F16WV0.57b | 11.672 | 9.792 | 5.017 | 1.871 | 46.068 | 36.665 | 41.046 | 44.568 | 18.946 | 26.416 | 19.328 | 7.254 | 9.862 | 14.458 | 31.070 | 0.000 | 0.000 | 10.295 | 13.826 | 8.515 | 8.980 | 8.399 | 6.286 | 0.138 | 2.947 | 7.342 |
| 42- F16WV0.57b | 11.672 | 9.792 | 5.017 | 1.871 | 46.068 | 36.665 | 41.046 | 44.568 | 19.222 | 29.365 | 18.665 | 5.848 | 8.544 | 15.441 | 29.985 | 0.000 | 0.000 | 9.919 | 14.090 | 8.868 | 9.459 | 7.942 | 5.603 | 0.875 | 3.202 | 7.736 |
| 84- F16WV0.37d | 7.242 | 4.736 | 3.546 | 1.168 | 47.023 | 35.698 | 40.268 | 43.676 | 23.295 | 29.135 | 19.885 | 5.511 | 10.150 | 14.831 | 34.237 | 0.000 | 0.000 | 11.365 | 13.870 | 9.288 | 9.849 | 7.198 | 4.402 | 0.713 | 2.327 | 7.654 |
| 89- F16WV0.57c | 11.210 | 9.547 | 4.890 | 1.796 | 45.786 | 36.575 | 41.205 | 44.342 | 19.325 | 25.836 | 18.695 | 7.283 | 9.248 | 14.225 | 30.742 | 0.000 | 0.000 | 10.094 | 13.918 | 8.544 | 9.127 | 8.323 | 5.869 | 0.114 | 2.913 | 7.175 |
| 41- F16WV0.57c | 11.210 | 9.547 | 4.890 | 1.796 | 45.786 | 36.575 | 41.205 | 44.342 | 19.270 | 29.194 | 18.810 | 5.855 | 8.490 | 15.630 | 29.906 | 0.000 | 0.000 | 9.228 | 13.742 | 8.921 | 9.391 | 7.829 | 5.285 | 0.753 | 3.044 | 7.304 |
| 94- F16WV0.77b | 11.690 | 10.086 | 4.977 | 1.895 | 45.123 | 35.494 | 41.452 | 42.860 | 17.316 | 25.332 | 19.035 | 6.641 | 11.666 | 16.369 | 22.558 | 0.000 | 0.000 | 10.414 | 14.448 | 8.268 | 8.845 | 8.515 | 7.270 | 0.827 | 3.643 | 9.482 |
| 47- F16WV0.77a | 11.700 | 10.081 | 5.236 | 1.884 | 46.094 | 36.171 | 41.364 | 42.877 | 19.716 | 29.623 | 18.978 | 6.179 | 10.329 | 15.755 | 28.242 | 0.000 | 0.000 | 7.923 | 10.865 | 6.254 | 8.434 | 8.311 | 5.821 | 0.845 | 3.261 | 7.752 |
| 36- F16WV0.37d | 7.242 | 4.736 | 3.546 | 1.168 | 47.023 | 35.698 | 40.268 | 43.676 | 22.834 | 30.115 | 23.297 | 5.919 | 8.995 | 15.821 | 31.314 | 0.000 | 0.000 | 11.425 | 14.852 | 7.221 | 11.905 | 5.864 | 3.179 | 0.876 | 0.916 | 3.893 |
| 46- F16WV0.77b | 11.690 | 10.086 | 4.977 | 1.895 | 45.123 | 35.494 | 41.452 | 42.860 | 19.516 | 28.610 | 20.104 | 6.018 | 8.812 | 16.086 | 26.318 | 0.000 | 0.000 | 7.873 | 12.165 | 5.861 | 9.399 | 8.251 | 5.580 | 1.167 | 3.368 | 8.117 |
| 93- F16WV0.77c | 11.212 | 9.838 | 4.853 | 1.819 | 44.788 | 35.337 | 41.029 | 42.503 | 17.961 | 24.877 | 19.115 | 6.488 | 10.226 | 16.868 | 22.551 | 0.000 | 0.000 | 10.437 | 14.107 | 7.941 | 9.989 | 8.596 | 7.233 | 0.674 | 3.582 | 9.009 |
| 45- F16WV0.77c | 11.212 | 9.838 | 4.853 | 1.819 | 44.788 | 35.337 | 41.029 | 42.503 | 19.952 | 28.296 | 20.894 | 5.938 | 8.273 | 16.545 | 26.278 | 0.000 | 0.000 | 7.784 | 11.647 | 6.514 | 9.571 | 8.432 | 5.283 | 1.144 | 3.548 | 7.953 |
| 88- F16WV0.57d | 8.050 | 6.068 | 3.874 | 1.218 | 45.130 | 35.824 | 40.023 | 43.186 | 23.676 | 25.056 | 19.133 | 7.272 | 9.833 | 15.025 | 25.643 | 0.000 | 0.000 | 10.080 | 14.061 | 8.743 | 9.108 | 7.997 | 6.262 | 0.563 | 2.842 | 6.818 |
| 40- F16WV0.57d | 8.050 | 6.068 | 3.874 | 1.218 | 45.130 | 35.824 | 40.023 | 43.186 | 22.566 | 27.741 | 19.575 | 5.685 | 8.506 | 15.677 | 29.325 | 0.000 | 0.000 | 8.650 | 14.264 | 6.511 | 9.849 | 7.557 | 5.484 | 0.603 | 3.131 | 6.845 |
| 35- F16WV0.17a | 10.337 | 10.044 | 5.234 | 2.259 | 45.146 | 33.512 | 34.605 | 40.302 | 22.845 | 39.045 | 21.776 | 4.791 | 12.775 | 17.435 | 35.178 | 0.000 | 0.000 | 9.509 | 13.245 | 6.485 | 8.654 | 0.000 | 0.069 | 0.001 | 0.000 | 0.000 |
| 92- F16WV0.17b | 8.106 | 6.259 | 3.859 | 1.145 | 44.678 | 35.109 | 40.359 | 41.740 | 21.347 | 23.676 | 19.133 | 6.402 | 9.929 | 16.268 | 21.344 | 0.000 | 0.000 | 10.337 | 14.456 | 9.398 | 9.443 | 8.278 | 7.288 | 1.183 | 3.672 | 8.395 |
| 34- F16WV0.17b | 10.247 | 9.978 | 4.718 | 2.250 | 44.395 | 33.788 | 34.682 | 40.211 | 21.819 | 39.468 | 22.112 | 4.573 | 11.586 | 16.076 | 35.702 | 0.000 | 0.000 | 9.492 | 12.975 | 6.425 | 8.445 | 0.000 | 0.065 | 0.001 | 0.000 | 0.591 |
| 33- F16WV0.17c | 10.308 | 9.784 | 4.742 | 2.132 | 44.519 | 33.579 | 34.713 | 40.278 | 21.927 | 39.327 | 21.646 | 4.574 | 11.440 | 14.830 | 35.199 | 0.000 | 0.000 | 9.208 | 13.171 | 6.234 | 9.077 | 0.000 | 0.067 | 0.001 | 0.000 | 0.590 |
| 83- F16WV0.17a | 10.337 | 10.044 | 5.234 | 2.259 | 45.146 | 33.512 | 34.605 | 40.302 | 22.866 | 34.626 | 19.729 | 6.226 | 11.616 | 15.557 | 33.318 | 0.000 | 0.000 | 7.010 | 15.671 | 6.575 | 8.094 | 3.065 | 0.000 | 0.010 | 1.018 | 2.218 |
| 44- F16WV0.77d | 8.106 | 6.259 | 3.859 | 1.145 | 44.678 | 35.109 | 40.359 | 41.740 | 22.578 | 26.898 | 20.254 | 4.935 | 10.139 | 16.350 | 24.459 | 0.000 | 0.000 | 7.177 | 11.349 | 5.634 | 9.369 | 8.196 | 5.543 | 1.015 | 3.360 | 7.481 |
| 81- F16WV0.17c | 10.308 | 9.784 | 4.742 | 2.132 | 44.519 | 33.579 | 34.713 | 40.278 | 23.628 | 34.596 | 18.254 | 5.416 | 7.197 | 15.487 | 33.689 | 0.000 | 0.000 | 7.652 | 14.944 | 5.647 | 8.539 | 4.949 | 0.000 | 0.020 | 0.932 | 2.160 |
| 32- F16WV0.17d | 7.084 | 6.010 | 3.666 | 1.172 | 43.917 | 33.255 | 34.689 | 40.422 | 27.045 | 36.346 | 21.200 | 4.433 | 10.855 | 14.616 | 35.605 | 0.000 | 0.000 | 8.961 | 12.735 | 6.035 | 8.521 | 1.987 | 0.065 | 0.001 | 0.006 | 0.800 |
| 82- F16WV0.17b | 10.247 | 9.978 | 4.718 | 2.250 | 44.395 | 33.788 | 34.682 | 40.211 | 22.522 | 34.704 | 18.576 | 5.662 | 7.309 | 15.606 | 31.797 | 0.000 | 0.000 | 7.484 | 14.924 | 5.710 | 6.956 | 4.953 | 0.000 | 0.019 | 0.970 | 2.205 |

Paires d'images utilisées pour l'étude de l'influence des paramètres



Annexe 2 : Architecture matérielle pour la reconnaissance vidéo temps-réel utilisant une approximation des moments de Zernike et des SVM

Nous présentons ici une méthode d'estimation des moments de Zernike permettant une implantation hardware. L'implantation de cette primitive sera couplée à une approximation de la fonction de décision du classifieur SVM.

Les propriétés d'invariance (rotation et translation), on fait des moments de Zernike outils très utilisés dans les applications de reconnaissance de formes par approche global. De plus, certains auteurs [Khotanzad, A. & al : 1990 ; Teague, M. 1980] ont mis en avant le pouvoir discriminant des moments de Zernike par rapport aux moments géométriques et au moment de Hu [Hu, K. M. 1962].

Les moments de Zernike sont définis par :

$$A_f(n, m) = \frac{m+1}{\pi} \sum_x \sum_y I(x, y) V_{nm}(x, y)$$

avec : $V_{nm}(r, \theta) = R_{nm}(r) e^{-in\theta}$ si on l'exprime en coordonnées polaires.

et le polynôme radial $R_{nm}(r) = \sum_{s=0}^{\frac{m-|n|}{2}} \frac{(-1)^s (m-s)! r^{m-2s}}{s! \left(\frac{m+|n|}{2} - s\right)! \left(\frac{m-|n|}{2} - s\right)!}$

Certaines méthodes d'approximation permettent d'obtenir une approximation des moments en utilisant des masques binaires [Aubret, O. & al : 2008]. Cette méthode propose de d'utiliser une matrice avec des valeurs binaires F_{nm} et son complément $\overline{F_{nm}}$ à la place de la matrice de la partie réelle et de la partie imaginaire de V_{nm} . La matrice F_{nm} est obtenue en appliquant l'algorithme de dithering de Floyd-Steinberg.

L'estimation des moments de Zernike en utilisant cette procédure est défini de la manière suivante :

$$A_{nm} = Are_{nm} + Aim_{nm}$$

$$\text{Avec } Are_{nm} = f_{\max} \times \sum \sum Fre_{nm}(x, y) \times \text{Im}(x, y) + f_{\min} \times \sum \sum \overline{Fre_{nm}}(x, y) \times \text{Im}(xy)$$

où $f_{\max} = \max_{x,y} (RE(V_{nm}(x, y)))$, $f_{\min} = \min_{x,y} (RE(V_{nm}(x, y)))$. Fre_{nm} et $\overline{Fre_{nm}}$ sont les masques binaires calculés en appliquant le dithering sur la partie réelle de V_{nm} .

De la même manière :

$$Aim_{nm} = f_{\max} \times \sum \sum Fim_{nm}(x, y) \times \text{Im}(x, y) + f_{\min} \times \sum \sum \overline{Fim_{nm}}(x, y) \times \text{Im}(xy)$$

où $f_{\max} = \max_{x,y} (IM(V_{nm}(x, y)))$, $f_{\min} = \min_{x,y} (IM(V_{nm}(x, y)))$. Fim_{nm} et $\overline{Fim_{nm}}$ sont les masques binaires calculés en appliquant le dithering sur la partie imaginaire de V_{nm} .

La robustesse à la rotation et au bruit, de l'estimation de ces moments a été étudiée et comparée au moment de Hu afin de valider leur utilisation dans le cadre d'applications de reconnaissance de formes.

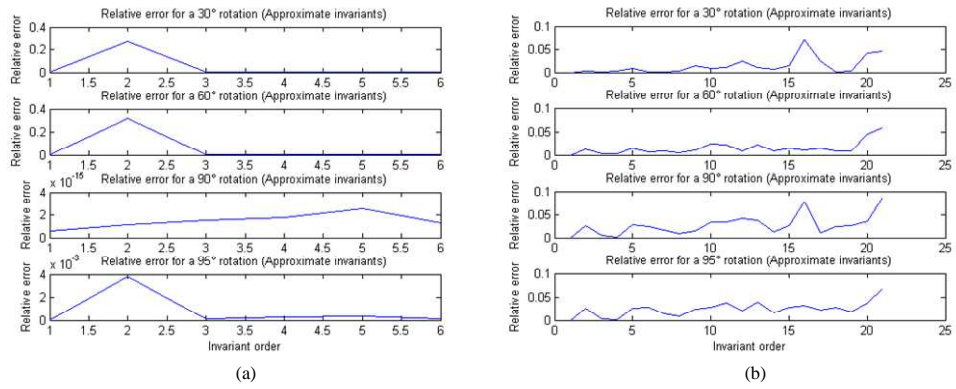


Figure 82 : résultats de la robustesse à la rotation

Dans un premier temps, nous avons tracé l'erreur entre les moments obtenus obtenu pour l'image originale et une image ayant subi une rotation. Les angles étudiés sont les même que ceux proposés par Derode [Ghorbel, F. & al : 2006] : $\{30^\circ, 60^\circ, 90^\circ \text{ et } 95^\circ\}$. Les résultats pour l'approximation des moments de Hu et des moments de Zernike sont disponible à la Figure 82-a et à la Figure 82-b. Il apparaît que l'approximation des moments de Zernike est beaucoup plus robuste à la rotation que l'approximation des moments de Hu. En effet, la valeur de l'erreur ne dépasse pas 5% pour les moments de Zernike alors qu'elle atteint plus de 20% dans le cas des moments approximés de Hu.

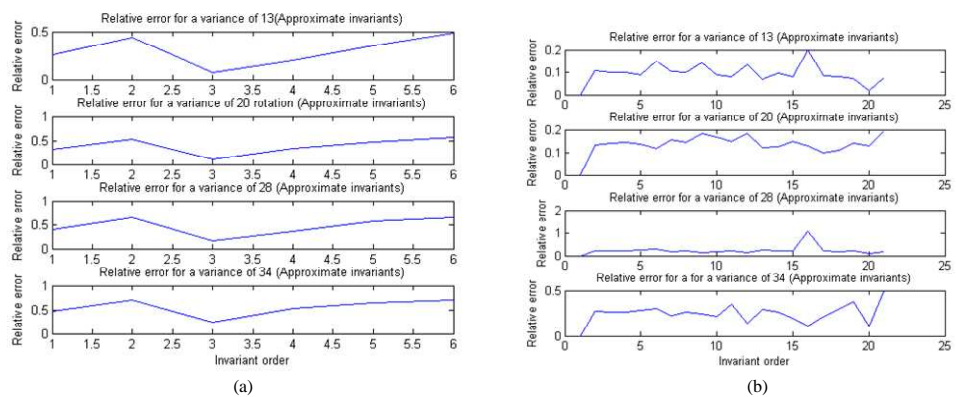


Figure 83 : résultats de la robustesse à l'ajout de bruit

De la même manière, nous avons étudiés la robustesse du bruit sur l'approximation des moments de Zernike et des moments de Hu. Pour cela nous calculons l'erreur entre les invariants obtenus pour l'image originale sans bruit avec des images possédant des niveaux de bruit blanc gaussien croissant dont les valeurs de variance sont les suivantes {13,20,28 et 34}.

Les résultats de cette étude sont représentés à la Figure 83-a et à la Figure 83. Il apparaît que les moments de Zernike approximatés sont encore une fois beaucoup plus robustes que les moments de Hu.

Afin de valider le pouvoir discriminant des moments de Zernike approximatés, nous les avons utilisés et comparés au moment de Zernike non-approximaté au sein d'une application de catégorisation. Pour cela, nous avons utilisés la base COIL avec laquelle nous avons formé quatre catégories (Mugs, boîtes rectangulaires, les voitures et les cannettes de boisson). Nous avons entraîné un classifieur de type SVM en utilisant les moments de Zernike. Puis afin de déterminer les performances, nous avons utilisé une méthode de validation croisée d'ordre 9.

Les résultats de catégorisation des moments approximatés et non-approximatés, pour différents paramètres du classifieur SVM, sont reportés au Tableau 11.

On peut remarquer que global l'erreur obtenue pour les moments de Zernike approximatés est plus importantes que pour les moments de Zernike exacts. Cependant cette erreur inférieure à 1,5% permet d'utiliser les moments de Zernike approximatés au sein d'une application de catégorisation et notamment sur des cibles hardware comme les FPGA.

| Valeur du paramètre σ des SVM | Moments de Zernike exacts (erreur obtenue par validation croisée en %) | Approximation des moments de Zernike exacts (erreur obtenue par validation croisée %) |
|--------------------------------------|--|---|
| 0.1 | 7.4 | 10.11 |
| 1 | 1.8 | 2.21 |
| 10 | 0.6 | 1.12 |
| 100 | 1.8 | 2.8 |
| 1000 | 11.4 | 33.79 |

Tableau 11 : résultats de catégorisation

Afin de réduire au maximum les ressources matérielles nécessaires pour réaliser l'implantation des moments de Zernike, nous avons étudié l'influence d'une sélection d'un sous-ensemble de paramètres dans l'ensemble de départ (16 paramètres). Pour créer ce sous-ensemble, nous proposons d'utiliser la méthode de sélection de paramètre SFS (Sequential Forward Selection) [Kittler, J. 1978].

Les résultats de catégorisation en utilisant la validation croisée sont disponibles au Tableau 12. Il apparaît que l'erreur de classification est plus élevée dans le cas d'une sélection de paramètres (1,12% pour l'ensemble complet, 2,7% pour le sous ensemble de cinq paramètres sélectionnés par la SFS). Afin de montrer l'intérêt de la sélection de paramètres, nous avons effectués un test en créant un sous-ensemble de même taille que l'ensemble sélectionné par la SFS (5 élément) mais en prenant de manière arbitraire les cinq premiers paramètres. On peut observer qu'au Tableau 12 que l'erreur de classification est 5 fois plus importante lorsqu'on sélectionne un sous ensemble sans la méthode SFS.

| | Ensemble complet : 16 invariants | Ensemble réduit : 5 premiers invariants | Ensemble réduit : 5 paramètres sélectionnés |
|---|-------------------------------------|--|--|
| Erreur de classification des SVM (%) | 1.12 | 10.85 | 2.7 |

Tableau 12 : résultats de sélection de paramètres

Enfin nous proposons une implantation de la méthode d'estimation des moments de Zernike décrite en VHDL. Ce module est synthétisé par le schéma fonctionnel présenté à la Figure 84. De plus, nous proposons aussi d'utiliser sur le même composant la fonction de décision d'approximation des SVM décrites dans [Mitéran, J. & al : 2003]. La génération de ce module est automatisée, le code VHDL est généré par une application PC en fonction des caractéristiques (moment de Zernike approximé) de la base d'apprentissage.




Figure 84: module d'estimation des moments de Zernike

Les résultats d'occupation du composant pour l'extraction des caractéristiques sont présentés au Tableau 13. Ces résultats sont comparés à une approche utilisant les mêmes paramètres d'entrée du classifieur (approximation des moments de Zernike) couplés avec la méthode de classification Adaboost.

On peut conclure que notre approche est plus économique en termes de coût hardware (453 slices contre 640 slices) ainsi qu'en termes d'erreur classification (2,7% contre 4,8%).

| | SVM avec selection de paramètres e=2.7% | | | Adaboost e=4.76% | | |
|------------------------|---|----------------------------|-------|---|----------------------------|-------|
| | Module ce calcul des moments de Zernike | Fonction de classification | Total | Module ce calcul des moments de Zernike | Fonction de classification | Total |
| Coût matériel (slices) | 259 | 194 | 453 | 640 | 61 | 701 |

Tableau 13 : coût matériel de l'implantation

Bibliographie

Armande, N., Montesinos, P., and Monga, O., "Thin Nets Extraction using a Multi-scale Approach," *Scale-Space Theory in Computer Science* Springer, 1997, pp. 361-364.

Aubretou, O., Bellach, B., Lew Yan Voon, L. F. C., Lamalle, B., Gorria, P., and Cathébras, G., "100x100 Pixel CMOS Retina for Real-Time Binary Pattern Matching," *Journal of Electronic Imaging - Special Issue on Quality Control by Artificial Vision*, vol. 13, no. 3, pp. 559-569, 2008.

Baumberg, A., "Reliable feature matching across widely separated views," *IEEE Conference on Computer Vision and Pattern Recognition 2000*, pp. 774-781.

Bay, H., Tuytelaars, T., and Van Gool, L., "SURF : Speeded Up Robust Features," *European Conference on Computer Vision 2006*, pp. 404-417.

Belongie, S., Malik, J., and Puzicha, J., "Shape Matching and Object Recognition Using Shape Context," *IEEE Pattern Analysis and Machine Intelligence*, vol. 2, no. 4, pp. 509-522, 2002.

Brown, M. and Lowe, D., "Invariant features from interest point groups," *BMVC 2002*, pp. 253-262.

Canny, J., "A computational approach to edge detection," *IEEE Pattern Analysis and Machine Intelligence*, vol. 8 pp. 679-698, 1986.

Carmichael, O. and Herbert, M., "Shape-Based Recognition of Wiry Objects," *IEEE Pattern Analysis and Machine Intelligence*, vol. 26, no. 12, pp. 1537-1552, 2004.

Chaudhuri, S., Chatterjee, S., Katz, N., Nelson, M., and Goldbaum, M., "Detection of blood vessels in retina images using two-dimensional matched filters," *IEEE Medical Imaging*, vol. 8, no. 3, pp. 263-269, 1989.

Choksuriwong, A., Laurent, H., Rosenberger, C., and Maaoui, C., "Object recognition using local characterisation and Zernike moments," *Conference on Advanced Concept for Intelligent Vision Systems LNCS*, 2005, pp. 108-115.

Chum, O. and Matas, J., "Geometric hashing with local affine frames," *International conference on Computer Vision and Pattern Recognition 2006*, pp. 879-884.

Deng, H., Zhang, W., Mortensen, E., Dietterich, T., and Shapiro, L., "Principal Curvature-Based Region Detector for Object Recognition," *IEEE Conference on Computer Vision and Pattern Recognition* 2007, pp. 1-8.

Dobie, M. R., Lewis, P. H., and Nixon, M. S., "Curvilinear network extraction from remotely sensed images," *Workshop on Machine Vision Applications* 1994, pp. 123-126.

[Eberly, D. & al : 1993] Ridges for image analysis. TR93-055. 1993. Departement of Computer Science, University of North Carolina, Chapel Hill.

Fischler, M. A., "The perception of linear structure: a generic linker," *Image Understanding Workshop* 1981, pp. 1565-1579.

Fischler, M. A. and Bolles, R. I., "Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography," *Comm of the ACM*, vol. 24 pp. 381-395, 1981a.

Fischler, M. A. and Tenenbaum, J. M., "Detection of roads and linear structures in low-resolution aerial imagery using a multisource knowledge integration technique," *Computer Graphics and Image Processing*, vol. 15 pp. 201-223, 1981b.

Fischler, M. A. and Wolf, C., "Linear delineation," *Computer Vision and Pattern Recognition*, pp. 351-356, 1983.

Foucherot, I. and Gouton, P., "Correlation between two colour images : use of the Fourier transform," *Symposium on signal processing and information technology* 2002, pp. 323-326.

Freeman, W. and Adelson, E., "The Design and Use of Steerable Filters," *IEEE Patten Analysis and Machine Intelligence*, vol. 13, no. 9, pp. 891-906, 1991.

Gao, K., Lin, S., Zhang, Y., Tang, S., and Ren, H., "Attention Model based SIFT keypoints filtration for image Retrieval," *International Conference on Digital Object Identifier* 2008, pp. 191-196.

Gauch, J. M. and Pizer, S. M., "Multiresolution analysis of ridges and valleys in grey-scale images," *IEEE Patten Analysis and Machine Intelligence*, vol. 15, no. 6, pp. 635-646, 1993.

Gerig, G., Kikinis, R., and Jolesz, F. A., "Image processing of routine spin-echo MR images to enhance vascular structures: Comparison with MR angiography," *3D Imaging in Medecine*, pp. 121-132, 1990.

Ghorbel, F., Derode, S., Mezhoud, R., Bannour, T., and Dhahbil, S., "Image reconstruction from a complete set of similarity invariants extracted from complex moments," *Pattern Recognition Letters*, vol. 27 pp. 1361-1369, 2006.

Goshen, L. and Shimshoni, I., "Balanced Exploration and Exploitation Model Search for Efficient Epipolar Geometry Estimation," *IEEE Pattern Analysis and Machine Intelligence*, vol. 30, no. 7, pp. 1230-1242, 2008.

Gouet, V., "Mise en correspondance d'images en couleur : Application à la synthèse de vues intermédiaires." **Université Montpellier 2**, 2000.

Gouet, V., Montesinos, P., and Pele, D., "A fast matching method for color uncalibrated images using differential invariants," *BMVC 1998*, pp. 376.

Haralick, R. M., "Ridges and valleys on digital images," *Computer Vision, Graphics, and Image processing*, vol. 22 pp. 28-38, 1983.

Harris, C. and Stephens, M., "A combined corner and edge detector," *4th Alvey Vision Conference 1988*, pp. 147-151.

Harris, F. J., "On the use of windows for harmonic analysis with the discrete Fourier transform," *Proceedings of the IEEE* 1978, pp. 51-83.

Hartley, R. I. and Zisserman, A., *Multiple View Geometry in Computer Vision*, 2nd ed. 2004.

Hu, K. M., "Visual pattern recognition by moments invariants," *IRE Transaction on Information Theory*, vol. 2 pp. 179-187, 1962.

Iverson, L. A. and Zucker, A., "Logical/Linear operators for images curves," *IEEE Pattern Analysis and Machine Intelligence*, vol. 17, no. 10, pp. 982-996, 1995.

Jiang, X. and Mojon, D., "Adaptive local thresholding by verification-based multithreshold probing with application to vessel detection in retinal images," *IEEE Pattern Analysis and Machine Intelligence*, vol. 25, no. 1, pp. 131-137, 2003.

Journaux, L., Destain, M. F., Mitéran, J., Piron, A., and Cointault, F., "Texture classification with generalized Fourier descriptors in dimensionality reduction : an overview exploration," *Workshop on Artificial Neural Networks in Pattern Recognition 2008*.

Kadir, K. and Brady, M., "Scale, Saliency and Image description," *International Journal of Computer Vision*, vol. 45, no. 2, pp. 83-105, 2001.

Kadir, K. and Brady, M., "An affine invariant salient region detector," *European Conference on Computer Vision 2004*.

Kass, M., Witkin, A., and Terzopoulos, D., "Snakes : active contour models," *International Journal of Computer Vision*, vol. 1, no. 4, pp. 321-331, 1988.

Khotanzad, A. and Hong, Y., "Invariant Image recognition by Zernike moments," *IEEE Pattern Analysis and Machine Intelligence*, vol. 12 pp. 489-497, 1990.

Kittler, J., "Feature set search algorithms," *Pattern Recognition and Signal Processing*, pp. 41-60, 1978.

Koenderink, J. J., *Solid Shape* Cambridge: MIT Press, 1990.

Koenderink, J. J. and van Doorn, J., "Two-plus-one-dimensional differential geometry," *Pattern Recognition Letters*, vol. 15, no. 5, pp. 439-443, 1994.

[Koller, T. M. & al : 1994] Multi-scale detection of curvilinear structures in 2-d and 3-d image data. Technical Report BIWI-TR-153. 1994. Zurich, Communication Technology Laboratory.

Koller, T. M., Gerig, G., Szekely, G., and Dettwiler, D., "Multiscale detection of curvilinear structures in 2-d and 3-d image data," *International Conference on Computer Vision* 1995, pp. 864-869.

Kweon, I. S. and Kanade, T., "Extracting topographic terrain features from elevation maps," *Computer Vision, Graphics, and Image processing : Image Understanding*, vol. 59, no. 2, pp. 171-182, 1994.

Lacroix, V. and Acheroy, M. s., "Constrained gradient: low-level tool for feature extraction.," *Mapping Buildings, Roads and other Man-Made Structures from Images* Wien: 1996, pp. 89-101.

Lazernik, S., Schmid, C., and Ponce, J., "Sparse Texture Representation Using Affine-Invariant Neighborhoods," *Conference on Computer Vision and Pattern Recognition* 2003, pp. 319-324.

Lindeberg, T., "Edge detection and ridge detection with automatic scale selection," *Computer Vision and Pattern Recognition* 1996, pp. 465-470.

Lindeberg, T., "Shape-adapted smoothing in estimation of 3-D shapes cues from affine deformations of local 2-D brightness structure," *Image and Vision Computing*, vol. 15, no. 6, pp. 415-434, 1997.

Lindeberg, T., "Edge detection and ridge detection with automatic scale selection," *International Journal of Computer Vision*, vol. 30, no. 2, pp. 79-116, 1998.

Lorenz, C., Carlsen, I.-C., Buzug, T. M., Fassnacht, C., and Weese, J., "A multi-scale line filter with automatic scale selection based on the hessian matrix for medical images segmentation," *Scale-Space Theory in Computer Vision* 1997a, pp. 152-163.

Lorenz, C., Carlsen, I.-C., Buzug, T. M., Fassnacht, C., and Weese, J., "Multi-scale line segmentation with automatic estimation of width, contrast and tangential direction 2d and 3d medical images," *Computer Vision, Virtual Reality and Robotics in Medecine and Medical Robotics and Computer Assited Surgery* 1997b, pp. 233-242.

Lowe, D., "Object recognition from local scale-invariant features," *International Conference on Computer Vision* 1999, pp. 1150-1157.

Lowe, D., "Distinctive image features from local scale-invariant keypoints," *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91-110, 2004.

Maintz, J. B. A., van den Elsen, P. A., and Viergever, M. A., "Evaluation of ridge seeking operators for multimodality medical image matching," *IEEE Pattern Analysis and Machine Intelligence*, vol. 18, no. 4, pp. 353-365, 1996.

Martin, D., Fowlkes, C., Tal, D., and Malik, J., "A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics," *International Conference on Computer Vision* 2001, pp. 416-423.

Martinez, A. M., "Recognition of partially occluded and/or imprecisely localized faces using probabilistic approach," *international conference on Computer Vision and Pattern Recognition* 2000, pp. 712-717.

Martinez-Perez, M., Hughes, A., Stanton, A., Thom, S., Bharah, A., and Parker, K., "Scale-space analysis for the characterisation of retina blood vessels," *Medical Image Computing and Computer Assisted Intervention* 1999, pp. 90-97.

Matas, J., Chum, O., Urban, M., and Paldla, T., "Robust wide baseline stereo from maximally stable extremal regions," *British Machine Vision Conference* 2002, pp. 384-393.

Matas, J., Chum, O., Urban, M., and Paldla, T., "Robust wide-baseline stereo from maximally stable extremal regions," *Image and Vision Computing*, vol. 22 pp. 761-767, 2004.

Mikolajczyk, K. and Schmid, C., "Indexing based on scale invariant interest points," *International Conference on Computer Vision* 2001, pp. 525-531.

Mikolajczyk, K. and Schmid, C., "An affine invariant interest point detector," *European Conference on Computer vision* 2002, pp. 128-142.

Mikolajczyk, K. and Schmid, C., "A Performance Evaluation of Local Descriptors," *IEEE Pattern Analysis and Machine Intelligence*, vol. 27, no. 10, pp. 1615-1630, 2005a.

Mikolajczyk, K., Tuytelaars, T., Schmid, C., Zisserman, A., Matas, J., Schaffalitzky, F., Kadir, K., and Van Gool, L., "A comparison of affine region detectors," *International Journal of Computer Vision*, vol. 65, no. 2, pp. 43-72, 2005b.

Mikolajczyk, K., Zisserman, A., and Schmid, C., "Shape Recognition with edge-based features," *BMVC* 2003, pp. 779-788.

Mitéran, J., Bouillant, S., and Boureynanne, E., "SVM approximation for real-time image segmentation by using an improved hyperrectangles-based method," *Real-Time Imaging*, vol. 9 pp. 179-188, 2003.

[Monga, O. & al : 1995] Thin nets and crest lines: application to satellite data and medical images. Rapport de Recherche 2480. 1995. Rocquencourt, INRIA.

Montesinos, P. and Alquier, L., "Perceptual organization of thin networks with active contour function applied to medical and aerial images," *International Conference on Pattern Recognition* 1996, pp. 647-651.

Montesinos, P., Gouet, V., Deriche, R., and Pele, D., "Matching color uncalibrated images using differential invariants," *Image and Vision Computing*, vol. 18 pp. 659-671, 2000.

Moreels, P. and Perona, P., "Evaluation of features detectors and descriptors based on 3D objects," *International Journal of Computer Vision*, vol. 73, no. 3, pp. 263-284, 2007.

[Nene, S. A. & al : 1996] Columbia Object Image Library (COIL-100). Technical Report CUCS-006-96. 1996.

Niemeijer, M., Stall, J., van Ginneken, B., Loog, M., and Abramoff, M. D., "Comparative study of retinal vessel segmentation methods on a new publicly available database," *SPIE Medical Imaging*, vol. 5370 pp. 648-656, 2004.

Opelt, A., Fusseneger, M., Pinz, A., and Auer, P., "Generic Object Recognition with Boosting," *IEEE Pattern Analysis and Machine Intelligence*, vol. 28, no. 3, 2006.

Petrou, M. and Kittler, J., "Optimal Edge detector," *IEEE Pattern Analysis and Machine Intelligence*, vol. 13, no. 5, pp. 1483-1491, 1991.

Porteous, I. R., *Geometric differentiation for the intelligence of curves and surfaces* Cambridge: Cambridge University Press, 1994.

Press, W. H., Teukolsky, S. A., Vetterling, W. T., and Flannery, B. P., *Numerical Recipes in C : the art of scientific computing*, 2nd ed. Cambridge: Cambridge University Press, 1992.

Schaffalitzky, F. and Zisserman, A., "Multi-view matching for unordered image sets," *European Conference on Computer Vision* 2002, pp. 414-431.

Schmid, C. and Mohr, R., "Local grayvalue invariants for image retrieval," *IEEE Pattern Analysis and Machine Intelligence*, vol. 19, no. 5, pp. 530-534, 1997.

Sedgewick, R., *Algorithms*, 2nd ed. Addison-Wesley, 1988.

SIDIBE, D. D., Université de Montpellier 2, 2007.

Sirovich, L. and Everson, R., "Analysis of large scientific datasets," *International Journal of SuperComputer Applications*, vol. 6 pp. 50-68, 1992.

[Skiljan, I. 2008] Irfanview : <http://www.irfanview.com/>. 2008.

- Smach, F., Lemaître, C., Gauthier, J. P., Mitéran, J., and Atri, M., "Generalized Fourier Descriptors with Applications to Objects Recognition in SVM Context," *Journal of Mathematical Imaging and Vision*, vol. 30 pp. 43-71, 2007.
- Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M. A., and van Ginneken, B., "Ridge-Based Vessel Segmentation in Color Images of the Retina," *IEEE Medical Imaging*, vol. 23, no. 4, pp. 501-509, 2004.
- Stall, J., Abramoff, M. D., Niemeijer, M., Viergever, M. A., and van Ginneken, B., "Ridge-Based Vessel Segmentation in Color Images of the Retina," *IEEE Medical Imaging*, vol. 23, no. 4, pp. 501-509, 2004.
- Steger, C., "An Unbiased Detector of Curvilinear Structures," *IEEE Patten Analysis and Machine Intelligence*, vol. 20, no. 2, pp. 113-125, 1998a.
- Steger, C., "Unbiased Extraction of Curvilinear Structures from 2D and 3D Images." Thesis, Fakultat für Informatik, Technische Universität München, 1998b.
- Teague, M., "Image Analysis via the general theory of moments," *Journal of the optical society of America*, vol. 70, no. 8, pp. 920-930, 1980.
- Tell, D. and Carlsson, S., "Combining appearance and topology for wide baseline matching," *European Conference on Computer Vision 2002*, pp. 814-828.
- Tran, H. and Lux, A., "A Method for ridge extraction," *Asean Conference on Computer Vision 2005*, pp. 96-111.
- Tuytelaars, T. and Van Gool, L., "Content-Based image retrieval on local affinely invariant regions," *International Conference on visual Information Systems 1999*, pp. 493-500.
- Tuytelaars, T. and Van Gool, L., "Matching widely based on affine invariant regions.," *International Journal of Computer Vision*, vol. 59, no. 1, pp. 61-85, 2004.
- Van Gool, L., Moons, T., and Ungureanu, D., "Affine/Photometric Invariants for Planar Intensity Patterns," *European Conference on Computer Vision 1996*, pp. 642-651.
- Vapnik, V., *The Nature of Statistical Learning Theory* Springer-Verlag, 1995.
- Viola, P. and Jones, M., "Rapid object detection using a boosted cascade of simple features," *International conference on Computer Vision and Pattern Recognition 2001*, pp. 511-518.
- Wallin, A. and Kuller, O., "Complete sets of complex Zernike invariants and the role of pseudo invariants," *IEEE Patten Analysis and Machine Intelligence*, vol. 10, no. 6, pp. 811-821, 1988.

Wang, L. and Pavlidis, T., "Detection of curved and straight segments from gray scale topography," *Computer Vision, Graphics, and Image processing : Image Understanding*, vol. 58, no. 3, pp. 352-365, 1993a.

Wang, L. and Pavlidis, T., "Direct gray-scale extraction of features for character recognition," *IEEE Patten Analysis and Machine Intelligence*, vol. 15, no. 10, pp. 1053-1067, 1993b.

Weickert, J., *Anisotropic Diffusion in Image Processing* Stuttgart, Germany: Teubner Verlag, 1998.

Zana, F. and Klein, J., "Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation," *IEEE Image Processing*, vol. 10, no. 7, pp. 1010-1019, 2001.