

UNIVERSITE SIDI MOHAMED BEN ABDELLAH
FACULTÉ DES SCIENCES ET TECHNIQUES FÈS
DÉPARTEMENT D'INFORMATIQUE



PROJET DE FIN D'ÉTUDES

MASTER SCIENCES ET TECHNIQUES
SYSTÈMES INTELLIGENTS & RÉSEAUX

SEGMENTATION D'IMAGES ENDOSCOPIQUES ET
CLASSIFICATION DES POLYPES PAR ANALYSE DE LA
TEXTURE ET DE LA COULEUR

LIEU DE STAGE : FACULTÉ DES SCIENCES ET TECHNIQUES DE FÈS

RÉALISÉ PAR : YASSINE RHAZ

SOUTENU LE : 15/06/2016

ENCADRÉ PAR : PR. ABBAD KHALID

DEVANT LE JURY COMPOSÉ DE :

PR. KHALID ABBAD :	ENCADRANT
PR. JAMAL KHARROUBI :	PRÉSIDENT
PR. FATIHA MRABTI :	EXAMINATRICE
PR. MOHAMED OUZARF :	EXAMINATEUR

ANNÉE UNIVERSITAIRE 2015-2016

Remerciement :

Je tiens à remercier tous ceux qui ont contribué, du début jusqu'à la fin, à la réalisation de ce travail. Je cite mon encadrant et professeur *Mr. Khalid Abbad* et mon professeur *Mr. Jamal Kharroubi*, dont j'ai l'honneur d'avoir été sous leurs encadrements. Ils ont été toujours disponibles, avec leurs savoir-faire, leurs connaissances dans le domaine, tout au long des quatre mois de mon projet de fin d'étude. Grâce à eux, j'ai pu découvrir le monde de la recherche que j'aimerais y adhérer. Sans oublier également leurs efforts fournis durant ces deux ans de formation du cycle master.

Ma gratitude va également à *Mr Tarik Ghannam*, qui n'a jamais refusé de me soutenir moralement et pédagogiquement. Depuis le premier jour, il était toujours présent quand j'avais besoin de ses conseils et de ses connaissances, notamment dans le domaine médical que j'ai pu découvrir grâce à lui, et également dans le domaine du traitement d'images. Je lui souhaite plein de succès dans la suite de ses études.

Je remercie également *Mme Fatiha Mrabti* et *Mr Mohamed Ouzarf*, qui vont lire et analyser mon travail, afin que je puisse bénéficier de leurs remarques et conseils. Et qui vont me faire l'honneur d'être présents parmi les membres de jury pour évaluer mon travail.

Un grand merci à mes parents qui m'ont soutenu moralement et financièrement, et qui ont su être patients tout au long de mon parcours d'études. Ainsi qu'à mes tantes, ma grand-mère, mes amis, que je leur dédie ce travail.

Résumé :

Les polypes du colon représentent un problème très répandu de santé publique. Ils touchent souvent les hommes et les femmes âgés de plus de 50ans, les fumeurs, les gens ayant un excès de poids, et peuvent être aussi héréditaires. Ce qui a incité beaucoup de chercheurs dans le domaine médical et d'aide à la décision, à prendre l'initiative, et mettre en place plusieurs techniques de traitement des polypes.

La coloscopie nous permet d'obtenir des images endoscopiques réelles en introduisant un fibroscope équipé d'une caméra, dans le corps humain. Ainsi nous pouvons surveiller toutes les régions du colon et détecter visuellement la présence d'éventuels polypes.

Notre travail consiste à traiter automatiquement ces images endoscopiques, en localisant le polype par une segmentation, et en analysant sa structure pour le but de déterminer sa nature (polype bénin ou malin), à travers une classification.

Abstract:

Colon polyps are a common public health problem. They often affect men and women aged over 50 years, smokers, fat people, and may also be hereditary. Witch has motivated many researchers in medical field and decision support to take the initiative and set up multiple polyps processing techniques.

Colonoscopy allows us to get real endoscopic images by introducing an endoscope equipped with camera in the human body. So we can monitor all colon regions and visually detect the presence of any polyps.

Our job is to automatically process these endoscopic images, by performing segmentation to localize polyp region. Then, analyze the structure and determine its nature (Benign or malignant polyp)

Mots clés : *segmentation, classification, imagerie médicale, coloscopie, polypes du colon, analyse de texture, couleur, descripteurs de texture, Gabor, Ondelette, Objet-Texture.*

Table des matières :

INTRODUCTION GENERALE	9
IMAGERIE MEDICALE	10
I.1. Introduction	10
I.2. Techniques d'imagerie médicale	10
I.2.1. Radiographie	10
I.2.2. Echographie	11
I.2.3. Tomodensitométrie (TDM)	12
I.2.4. Imagerie par résonance magnétique (IRM)	13
I.2.5. Les images endoscopiques	14
I.2.5.1. Composants et fonctionnement du fibroscope	14
I.2.5.2. Techniques de base	15
I.2.5.3. La chromoendoscopie	19
I.3. Problématique :	20
I.3.1. Segmentation :	21
I.3.2. Classification à base de texture	22
I.3.3. Les polypes du colon	22
I.3.3.1. Classification morphologique	22
I.3.3.2. Les cryptes de Kudo (Kudo Pit Patterns)	23
I.3.3.3. Pit Patterns modifié par Hideki Mitooka	24
I.3.4. Description du travail à réaliser	25
ETAT DE L'ART	26
II.1. Introduction	26
II.2. Analyse de texture pour la Segmentation	26
II.3. Analyse de la texture pour la classification	27
II.4. Descripteurs de texture	28
II.4.1. Le filtre de Gabor	29
II.4.2. Les ondelettes	31
II.4.2.1. L'ondelette de Haar	33
II.4.2.2. L'ondelette de Daubéchies	37
II.4.3. GLCM (Matrice des cooccurrences des niveaux de gris)	39
II.4.4. Les motifs binaires locaux (Local Binary Patterns)	44
II.5. Conclusion	48
PRESENTATION DES METHODES	49

III.1.	Introduction	49
III.2.	Présentation de la méthode de base	49
III.2.1.	Problème posé	49
III.2.2.	Invariance du filtre de Gabor par autocorrélation (AGF)	50
III.2.3.	Classification	52
III.2.3.1.	Texture homogène de l'autocorrélation (AHT)	53
III.2.3.2.	AGF textons	53
III.2.4.	Schéma de l'algorithme	55
III.3.	Amélioration de la méthode	55
III.3.1.	Méthode de décomposition objet - texture	56
III.3.2.	Mise en place du nouveau descripteur	58
III.4.	Conclusion	59
IMPLEMENTATION ET RESULTATS		60
IV.1.	Introduction	60
IV.2.	Classification	61
IV.2.1.	Techniques d'évaluations	63
IV.2.1.1.	Evaluation par validation croisée (cross-validation)	63
IV.2.1.2.	Evaluation par échantillonnage aléatoires (random simpling)	63
IV.2.2.	Méthode de base	63
IV.2.2.1.	Descripteur AGF_textons	64
IV.2.2.2.	Descripteur AGF_AHT	66
IV.2.3.	Méthode proposée	68
IV.2.3.1.	Descripteur ACTDtextons	68
IV.2.3.2.	Descripteur ACTD_AHT	73
IV.3.	Synthèse	76
IV.4.	Segmentation	77
IV.5.	Présentation de l'application	79
IV.5.1.	Onglet de segmentation	80
IV.5.2.	Onglet des descripteurs	81
IV.5.3.	Onglet de classification	85
IV.6.	Conclusion	86
CONCLUSION ET PERSPECTIVES		87

Table des figures :

Figure 1 : Radiographie des poumons.....	10
Figure 2 : Echographie d'un fœtus.....	11
Figure 3 : Architecture d'une machine TDM	12
Figure 4 : Composant d'un scanner IRM.....	13
Figure 5 : IRM Cérébrale	13
Figure 6 : Composants d'un endoscope	14
Figure 7 : Endoscopie digestive haute	15
Figure 8 : Maladie de l'œsophage de Barrett.....	15
Figure 9 : Image du duodénum	16
Figure 10 : Image de l'intestin grêle	17
Figure 11 : Photo d'une vidéocapsule.....	17
Figure 12 : Endoscopie du Colon.....	18
Figure 13 : Présence d'un polype dans le Colon.....	18
Figure 14 : a) image endoscopique normale b) image obtenue après l'application du Carmin d'indigo	19
Figure 15 : A) Tumeur urothéliale faiblement perçue en lumière blanche. B) Utilisation des Bandes Spectrales Etroite donnant plus de précision.....	20
Figure 16 : les différentes formes de polypes	22
Figure 17 : quelques photos endoscopiques des polypes du colon (a polype pédiculé b) polypes sessile c) polypes plan.....	23
Figure 18 : les cryptes de Kudo et al	24
Figure 19 : les cryptes de Kudo modifié par H.Mitooka	24
Figure 20 : Schéma global du système.....	25
Figure 21 : Polype avec une texture différente de la muqueuse normale	28
Figure 22 : Exemple d'un ensemble de filtres avec 6 échelles et 8 orientations (48 filtres).	30
Figure 23 : Extraction des caractéristiques texturales d'un polype avec les filtres de Gabor.....	31
Figure 24 : translation de l'ondelette. A gauche $\psi(t)$. A droite $\psi(t - k)$	32
Figure 25 : Changement d'échelle d'une ondelette	32
Figure 26 : les ondelettes et leurs fonctions d'approximation	34
Figure 27 : décomposition d'un signal à l'aide de la matrice de Haar.....	35
Figure 28: Filtre permettant la décomposition de l'image : $\phi_{0PB}, \psi_{10}: PHH, \psi_{20}: PHV, \psi_{30}: PHD$	36
Figure 29 : Décomposition de l'image en ondelettes de Haar. a) : Approximation (filtrage passe-bas) b) : détails horizontaux. c) détails verticaux. d) détails diagonaux	36
Figure 30 : Exemple d'ondelette de daubéchies	37
Figure 31 : les voisins d'un pixel central [0,0] selon une distance et orientation données (d=1 voisins adjacents et $\theta = [0,45^\circ, 90^\circ, 135^\circ]$).....	39
Figure 32 : Calcul de la matrice des cooccurrences d'une image à 5 niveaux de gris.....	40
Figure 33 : Méthode de calcul de l'image filtré par la GLCM	43

Figure 34 : Image filtré par GLCM de distance égale à 1. Résultats des mesures Haralick : Les colonnes représentent les mesures prise respectivement : Contraste, Dissimilarité, et homogénéité. Les lignes représentent les orientations : 0°,45°,90°,135°	44
Figure 35 : Exemple de voisinage LBP caractérisé par P : nombre de voisins et R : le rayon (ou distance)	45
Figure 36 : Calcul du motif binaire local d'un pixel central avec 8 voisins adjacents (P=8 et R=1)	46
Figure 37 : pit patterns CH de Dinis Ribeiro. Groupe I : Normal, Groupe II : Précancéreux, Groupe III : cancéreux	49
Figure 38 : pit pattern de R.Singh : A : tissu normal. B, C Précancéreux. D : Cancéreux	50
Figure 39 : A) Gauche : Image Initial, Droite : Matrice d'un pixel B) Gauche : image orienté, Droite : décalage des lignes. C) Gauche : image redimensionné, Droite : décalage des colonnes.	51
Figure 40 : Schéma montrant les étapes de la création du dictionnaire	54
Figure 41 : Schéma montrant la création d'un histogramme de textons à partir du dictionnaire des textons	54
Figure 42 : Schéma global de la méthode de base	55
Figure 43 : fonction de seuillage $w(s)$ (article [30])	57
Figure 44 : Décomposition de l'image en texture et cartoon (objet) avec $\sigma = 10$	58
Figure 45: Schéma global de la méthode proposée.....	59
Figure 46 : A gauche polype en mode RGB, A droite l'information du rouge de l'image	60
Figure 47 : A gauche cancer en mode RGB, A droite l'information du rouge de l'image.....	61
Figure 48 : Evolution du temps de calcul par image, en fonction du nombre de textons choisi	64
Figure 49 : Résultats obtenus par validation croisée sur la classe des polypes	65
Figure 50 : Résultat obtenu par validation croisée sur la classe des cancers	65
Figure 51 : Evaluation du temps par rapport aux pas du sigma (ps), et au nombre de textons par image (nt)	68
Figure 52 : évaluation par validation croisée nt = 2.....	69
Figure 53 : évaluation par validation croisée nt = 4.....	70
Figure 54 : évaluation par validation croisée nt = 6.....	70
Figure 55 : Evolution du temps par rapport au choix du pas du sigma.....	73
Figure 56 : Evaluation par validation croisée	74
Figure 57 : Evaluation par échantillonnage aléatoire sur 20%	74
Figure 58 : Evaluation par échantillonnage aléatoire sur 40%	75
Figure 59 : Evaluation par échantillonnage aléatoire sur 60% de donnée d'apprentissage.....	75
Figure 60 : Evaluation par échantillonnage aléatoire sur 80% de donnée d'apprentissage.....	76
Figure 61: récapitulation des meilleurs résultats obtenus pour chaque descripteur.....	77
Figure 62: Présentation de l'application (elle pointe sur l'onglet de segmentation).....	79
Figure 63 : présentation de l'onglet de segmentation	80
Figure 64 : Affichage des étapes de segmentation.....	81
Figure 65 : Présentation de l'onglet des descripteurs	82
Figure 66 : exemple d'images de textons utilisées	82
Figure 67 : les filtres de gabor utilisés	83
Figure 68 : Les réponses aux filtres de gabor	83

Figure 70 : Histogramme des textons de l'image (vecteur caractéristique).....	84
Figure 71 : l'onglet classification (partie nouvel apprentissage).....	85
Figure 72 : partie importation des données d'apprentissage	85
Figure 73 : Fenêtre de la classification d'une image (polype bénin ou malin).....	86

Liste des tableaux :

Tableau 1 : résultat obtenus par la technique d'échantillonnage aléatoire	66
Tableau 2 : Evaluation de la méthode AGF_AHT par validation croisée	67
Tableau 3 : Evaluation de la méthode AGF_AHT par échantillonnage aléatoire	67
Tableau 4 : Evaluation par échantillonnage aléatoire pour $nt = 2$	71
Tableau 5 : Evaluation par échantillonnage aléatoire pour $nt = 4$	72
Tableau 6 : Evaluation par échantillonnage aléatoire pour $nt = 6$	72

Introduction générale

L'imagerie médicale constitue un grand apport à la médecine moderne, qu'on ne peut négliger en aucun cas. C'est l'un des critères sur lesquels le médecin s'appuie pour sortir avec un bon diagnostic décrivant l'état du patient. Les techniques d'imageries médicales sont nombreuses et chacune apporte son utilité selon les prescriptions de l'expert : le médecin décide lesquelles des techniques sont les plus adéquates vis-à-vis la gravité de la maladie ou de l'organe à mettre sous analyse.

Grâce à ces techniques d'acquisition d'images médicales qui ne cessent d'évoluer jusqu'à présent, le médecin est désormais capable de voir à œil nu, ce qui se passe à l'intérieur du corps humain, et donc d'intercepter et déterminer exactement l'organe ou la région infectée par un virus ou une tumeur. Ce qui délimite le domaine d'analyse, et ainsi, le diagnostic peut se faire au temps voulu et avec précision.

L'importance de l'imagerie médicale réside surtout dans la détection de corps étrangers. C'est à dire des tissus anormaux comme des ulcères ou des polypes. Puis le dépistage (savoir de quoi il s'agit). Ce sont des anomalies que le médecin doit détecter trop tôt pour pouvoir les soigner sans infliger des dommages dans le corps humain.

L'endoscopie est la meilleure technique d'imagerie permettant le traitement des polypes, puisqu'elle se base sur des images réelles et en haute définition, captées par la caméra du fibroscope en l'introduisant directement dans le corps humain. En plus de la caméra, d'autres équipements sont mis en place pour effectuer plusieurs tâches comme le prélèvement d'échantillons pour faire de la biopsie, éradiquer le polype, éliminer les calculs...

Notre recherche est basée sur des images acquises à partir de la coloscopie. Ces images contiennent des polypes qui sont l'objet principal du travail. Donc, premièrement il faut extraire le polype de son arrière-plan qui est la muqueuse normale du colon, à travers une segmentation basée sur la couleur et la texture. Deuxièmement, il faut savoir que les polypes sont généralement classifiés en bénins et malins, par conséquent notre but serait de concevoir un système de classification binaire, nous permettant de déterminer la classe du polype, en analysant sa texture.

Dans ce qui suit, le chapitre I traite brièvement les différentes techniques d'imagerie médicale, suivi d'une problématique visant à mieux connaître les caractéristiques des polypes et les techniques de classification et d'analyse de texture. Le chapitre II est l'état de l'art dans lequel nous présentons les travaux effectués au niveau de la segmentation et de la classification à base de texture. Dans le chapitre III, nous décrivons en détail la méthode de base que nous avons sélectionnée, puis la nouvelle méthode que nous avons mise en place. Ensuite, dans le chapitre IV, nous présentons les résultats obtenus, et leurs interprétations. Et finalement une conclusion et les perspectives.

Chapitre I

Imagerie Médicale

I.1. Introduction

L'objectif de ce chapitre est de découvrir les différentes techniques d'imagerie médicale les plus souvent utilisées pour l'aide au diagnostic. Chaque technique a ses points forts et points faibles, selon le coût, le risque d'effets secondaires (cas d'utilisation des rayons) qui peuvent apparaître chez un patient avec un état particulier, et aussi par rapport à l'organe ou bien la matière à analyser (tissu, os...).

Afin de mieux enchaîner avec l'état de l'art, la deuxième partie de ce chapitre est consacrée à la problématique, dans laquelle nous allons détailler le but de ce travail, puis les recherches que nous avons effectuées au sujet des polypes du colon, à savoir des études portant sur leurs caractéristiques morphologiques et texturales. Ensuite nous finissons avec quelques notions sur la segmentation et la classification à base de texture.

I.2. Techniques d'imagerie médicale

I.2.1. Radiographie

La radiographie [1] est une technique d'imagerie médicale basée sur les rayons X, largement utilisée pour l'analyse des poumons (radiographie thoracique), afin de détecter des pathologies cardiaques et respiratoires telles que l'asthme, tuberculose, cancer... ainsi que la détection des fractures au niveau des os, analyse dentaire etc...



Figure 1 : Radiographie des poumons

(http://upload.wikimedia.org/wikipedia/commons/c/c8/Chest_Xray_PA_3-8-2010.png)

Imagerie Médicale

Comme le montre la **Figure 1**, il s'agit d'un examen de poumons, effectué par une machine à rayons X en mode Postérieur-Antérieur faisant allusion à l'orientation du corps humain et au sens de pénétration des rayons X, transperçant le patient de son postérieur jusqu'à sortir de son antérieur. Pour un examen de poumons les médecins utilisent cette position car elle montre plus de détails sur les poumons, puisque le cœur est situé à l'antérieur. En revanche, si on choisit la position inverse on obtiendra une image de poumons, moins claire.

Une fois arrivés, les rayons sont projetés sur ce qu'on appelle Film ou Cliché radiographique obtenu par rayon X.

I.2.2. Echographie

C'est une autre technique d'imagerie médicale basée sur les ultrasons [2], appelée aussi **Ultrasonographie** ou (Sonographie). Le mot Echographie est composé de deux mots :

1. **Echo** : les échos sont des ondes réfléchies par l'objet en question.
2. **Graphie** : interprétation graphique des échos reçus.



Figure 2 : Echographie d'un fœtus.
(<http://www.babybankruptcy.com/img/ultrasound2-crop.jpg>)

Comme les rayons X, les ondes ultrasoniques sont aussi capables de transpercer le corps humain, et donc explorer ce qui se passe dans la région concernée. Ce sont des ondes dotés d'une grande fréquence (>20Khz) dépassant l'intervalle perçu par l'oreille humaine.

Afin d'obtenir une image échographique (**Figure 2**), le spécialiste se sert d'une sonde qui émet le signal et le reçoit après avoir heurté un obstacle. Alors grâce à un ordinateur on peut déterminer la position de l'obstacle et donc le dessiner pour former l'image du fœtus.

Les types échographies [3] en médecine sont répartis selon l'organe à analyser. Parmi ces types on cite :

Imagerie Médicale

- Echographie abdominale
- Echographie rénale
- Echographie cardiaque (Echocardiographie)
- Echographie prostatique
- Echographie mammaire
- Echographie endovaginale

I.2.3. Tomodensitométrie (TDM)

Connu par le **Scanner** ou **Scanographie** [4]. C'est une technique moderne utilisant les rayons X, donc similaire à la radiographie, sauf que cette fois, plusieurs images sont captées avec différents angles, et donc on est en mesure de les rassembler pour représenter l'objet dans l'espace (3D), ce qui donne énormément d'informations acquises par rapport à la radiographie standard.




Figure 3 : Architecture d'une machine TDM
(<http://blausen.com/fr/video/tomodensitogramme/>)

Le problème de la radiographie vient du fait que la détection d'anomalies est très faible, car en se fiant à des radiographies prises par quelques angles, cela ne garantit en aucun cas l'absence d'une lésion.

Dans la **Figure 3**, on remarque un émetteur et récepteur de rayons X étant en mouvement de rotation autour du patient, afin d'effectuer une prise de clichés en 360°. Puis grâce à la table glissante, on obtient des prises de tous les organes du corps.

I.2.4. Imagerie par résonance magnétique

(IRM)

L'IRM [5] est une technique moderne par rapport à celles que nous avons abordées. Elle a l'avantage d'être sans risque et capable de distinguer les différents tissus du corps, ce qui donne une image anatomique plus proche de la réalité que celle calculer par le scanner TDM.

Comme l'indique son nom, cette technique se base sur un phénomène physique très intéressant appelé **résonance magnétique nucléaire**.

Le principe de la résonance consiste à exciter les protons d'hydrogènes de l'organisme, grâce à l'emploi d'un champ magnétique, suivi d'une onde radio en utilisant un grand aimant et une bobine. Ainsi les protons d'hydrogène agissent comme un aimant et donc ils empruntent la même direction des champs magnétiques.

Afin de construire l'image et de distinguer les différents tissus, on calcule le temps de relaxation de chaque proton, cela renseigne sur l'environnement dans lequel il se trouve.




Figure 4 : Composant d'un scanner IRM

(https://nationalmaglab.org/images/education/magnet_academy/learn_basics/articles/mri/mri-scanner.jpg)




Figure 5 : IRM Cérébrale

(<http://blog.letudiant.fr/medecine-examen-classant-national/files/2013/08/FLAIRok.jpg>)

L'IRM est fortement déconseillée si le corps du patient dispose d'un engin comme un stimulateur cardiaque, car le métal peut être endommagé lors de l'examen. Et aussi pour les patients ayant des tatouages de peur d'éventuelles brûlures.

I.2.5. Les images endoscopiques

Toutes les techniques que nous avons découvertes utilisent des méthodes indirectes pour synthétiser l'image montrant l'intérieur du corps humain. Or l'endoscopie est beaucoup plus précise puisqu'il s'agit d'images en temps réel, prise à l'intérieur du corps en utilisant un endoscope : un tube mené d'une caméra qu'on introduit par voie orale (endoscopie haute) ou rectale (endoscopie basse). Cela dépend du diagnostic à effectuer.

I.2.5.1. Composants et fonctionnement du fibroscope

Comme le montre la **Figure 6**, l'endoscope moderne ou fibroscope est constitué d'une caméra à haute définition équipée d'une lumière pour voir dans le noir. Ainsi qu'un tube en fibres optiques où chaque fibre transmet une information sur l'image.

La direction de la caméra peut être contrôlée par la zone de contrôle afin de filmer toutes les zones. On peut aussi prendre des captures grâce à des boutons. Le fibroscope est équipé aussi d'un fil permettant de le connecter à un ordinateur pour mieux visualiser ou faire d'éventuels traitements d'images acquises.




Figure 6 : Composants d'un endoscope
(<http://www.veterinaire-lambesc.fr/wp-content/uploads/2012/08/endo1.jpg>)

I.2.5.2. Techniques de base

a) Gastroskopie :

Ou ce qu'on appelle **endoscopie digestive haute** [6]. Elle est utilisée pour explorer le système digestif humain en introduisant le tube de l'endoscope par voie orale allant de la bouche puis passant par l'œsophage jusqu'à l'arrivée à l'estomac (**Figure 7**).

A l'aide de l'endoscope on peut voir clairement l'état des tissus des différentes parties du système digestif. Comme le montre la **Figure 8**, l'œsophage de Barrett représente toute la région en rouge, où des cellules commencent à se métamorphoser. L'une d'elles peut se développer en polypes cancéreux.

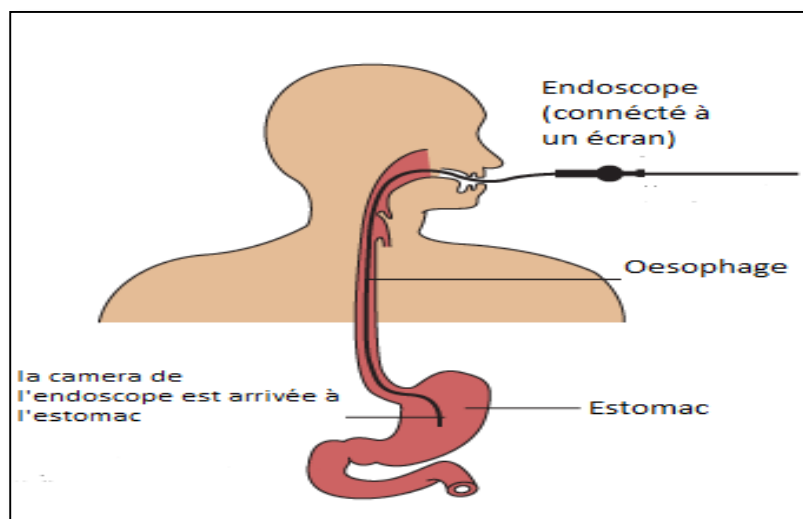


Figure 7 : Endoscopie digestive haute

<http://www.newcastlesurgery.com.au/wp-content/uploads/2012/06/gastroscopy-1.gif>

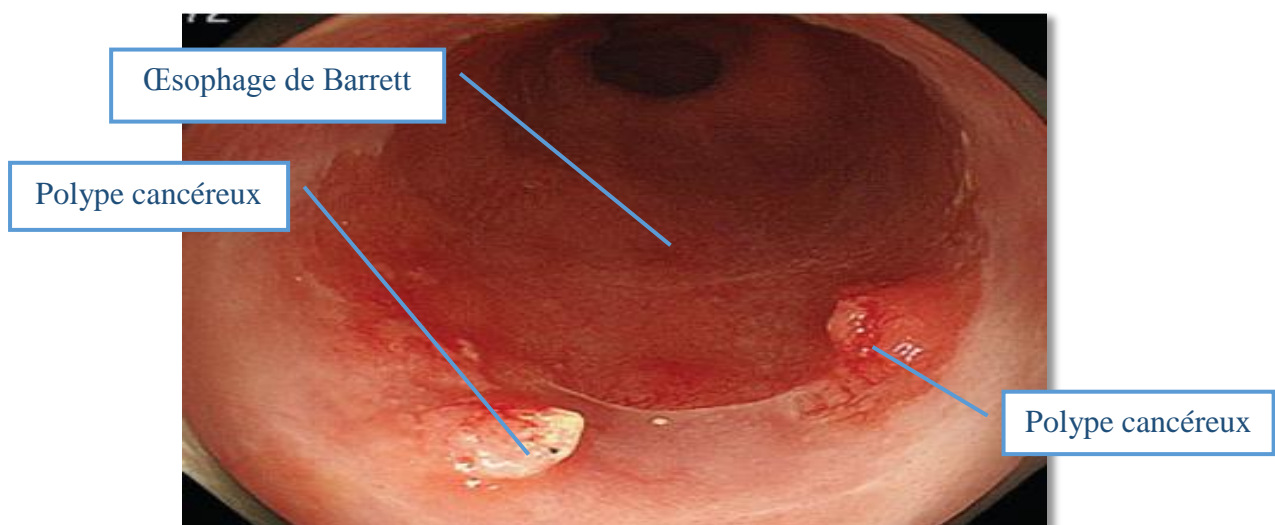


Figure 8 : Maladie de l'œsophage de Barrett

<http://atm.amegroups.com/article/viewFile/3534/4377/17652>

b) Duodéoscopie :

Le duodénum [7] est la partie supérieure de l'intestin grêle. Son rôle est très important, puisque il est équipé de cellules capables de fabriquer des enzymes permettant la digestion d'aliments. Il travaille avec la Pancréas qui permet de produire des sucs pancréatique qui servent à la digestion de certains sucres et protéines, et il coopère aussi avec la Vésicule biliaire qui produit de la bile afin d'aider l'intestin grêle à absorber des graisses et des vitamines indispensable.

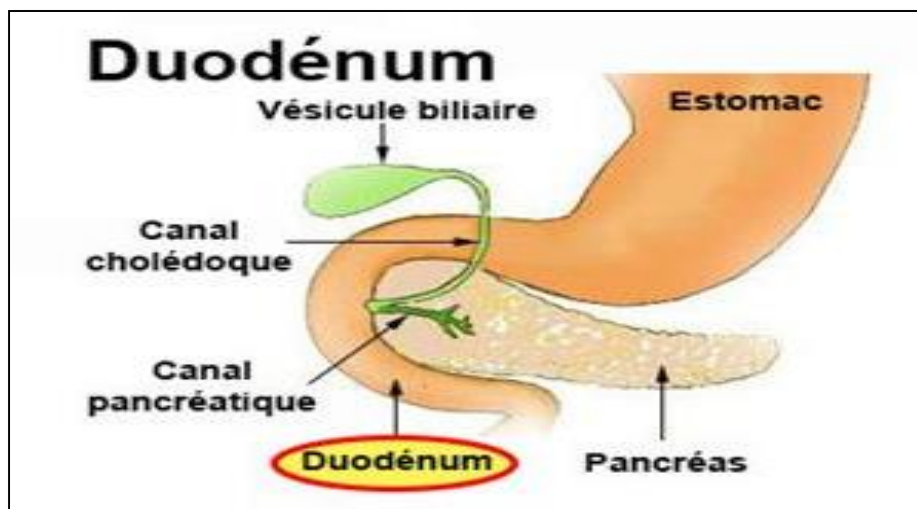


Figure 9 : Image du duodénum

http://www.docteurcliv.com/galerie-photos/image_3245_m.jpg

Donc le duodénum joue un rôle plutôt chimique que d'être un simple tube qui fait circuler les aliments.

À cause de son importance dans le système digestifs une analyse spécifique lui a été consacré appelée **Duodéoscopie**.

La Duodéoscopie suit le même trajet que celui de la gastroscopie jusqu'à l'organe en question qui est le duodénum. Elle nous permet de visualiser l'organe pour détecter d'éventuel polype ou ulcères duodénaux. Ces derniers peuvent être causés par des bactéries (*H.pylori*) ou par de grandes concentrations d'acides dans la région.

c) Entéoscopie :

L'Entéoscopie concerne la visualisation de l'intestin grêle : c'est un organe qu'on trouve après le duodénum, donc relié à l'estomac, et qui est entouré du gros intestin qui est le colon comme le montre la **Figure 10**.

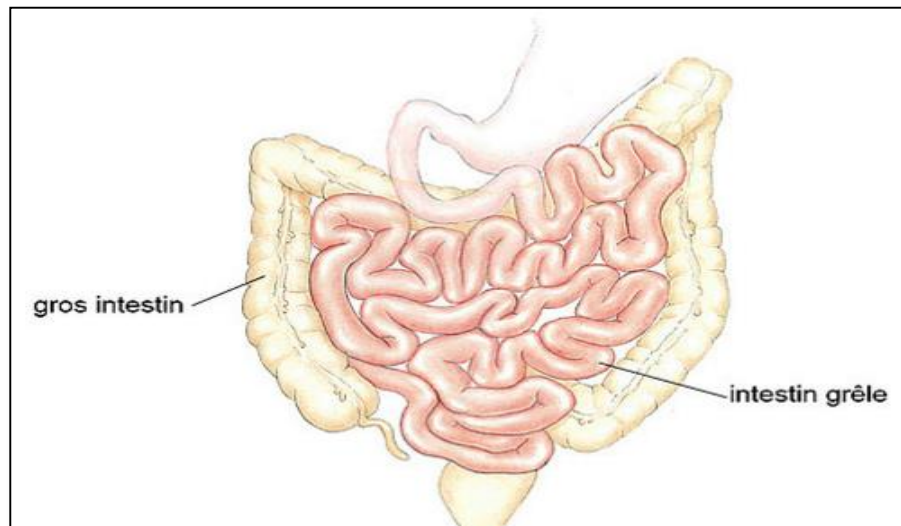


Figure 10 : Image de l'intestin grêle

https://assets.krebsliga.ch/img/duendarm_fr_5863.jpg

Il est clair d'après la figure que la longueur de l'intestin grêle est assez importante. Elle peut varier de 4m à 7m, ce qui fait de lui un grand constituant de l'appareil digestif. Il est appelé aussi petit intestin, faisant allusion à son diamètre qui est plus petit que celui du colon.

Vu la fragilité de cet organe, on n'utilise pas un fibroscope mais plutôt un dispositif appelé vidéocapsule **Figure 11**. Et l'opération est appelé endoscopie par capsule.

Cette capsule est avalée par le patient, ensuite la caméra intégrée commence à prendre des photos dans les différentes parties de l'intestin grêle, et les envoie à un boîtier que porte le patient au niveau de son abdomen.



Figure 11 : Photo d'une vidéocapsule

http://www.lookfordiagnosis.com/mesh_info.php?term=Endoscopie+Par+Capsule&lang=4#

d) Coloscopie :

Ce teste permet au docteur d'examiner le colon : il s'agit d'un gros intestin situé dans la cavité abdominale. Comme le montre la **Figure 12**, le colon entoure l'intestin grêle allant de l'anus jusqu'à l'autre extrémité appelé caecum.



Figure 12 : Endoscopie du Colon

<http://clinique1037.com/wp-content/uploads/2014/09/colonoscopia-554x388.jpg>

La coloscopie est utilisée pour la recherche d'un polype du côlon dans le cadre du dépistage, ou lors de la présence de symptômes comme un saignement intestinal ou une diarrhée chronique, ou de douleurs abdominales non interprétées.

Contrairement à la gastroscopie cette fois on insère l'endoscope à partir de l'anus.




Figure 13 : Présence d'un polype dans le Colon

<http://lapsurgerybrisbane.com.au/wp-content/uploads/2012/04/Polyps-of-theColon-and-Rectum2.jpg>

I.2.5.3. La chromoendoscopie

a) Chromoendoscopie par colorants

Afin de mieux visualiser les caractéristiques des tissus, et ainsi augmenter la précision du diagnostic et de dépistage des muqueuses anormales, les endoscopes sont équipés de liquides appelés agents de contraste, qu'on applique directement sur la muqueuse. Parmi les substances utilisées on cite :

- Le bleu du méthylène
- L'iode de Lugol
- Le bleu de toluidine
- Le violet de gentiane
- Le Carmin d'indigo

L'utilisation de ces solutions dépend de la capacité du tissu à l'absorber.

Comme nous pouvons le constater dans la **Figure 14** l'utilisation des colorants nous a permis d'obtenir une bonne représentation des tissus afin d'être plus précis dans la biopsie ou lors d'une intervention chirurgicale




Figure 14 : a) image endoscopique normale b) image obtenue après l'application du Carmin d'indigo

<https://d3gef7ppmbvsns.cloudfront.net/content/qjmed/106/2/117/F2.large.jpg?width=800&height=600&carousel=1>

b) Chromoendoscopie virtuelle

Cette technique de chromoendoscopie, appelée aussi **Endoscopie à Bandes Spectrales Etroites**, tente de réaliser une coloration virtuelle des tissus, sans l'aide des colorants. Son principe est d'exploiter la profondeur de pénétration de lumière issue de l'endoscope. On procède à un éclairage du tissu avec une série de spectres dont les bandes d'émission sont différentes, ce qui nous aide à distinguer la structure du tissu en se fiant à la profondeur.




Figure 15 : A) Tumeur urothéliale faiblement perçue en lumière blanche. B) Utilisation des Bandes Spectrales Etroite donnant plus de précision

<http://urofrance.org/fileadmin/documents/data/PU/2011/v21i8/S1166708711000911/main.pdf>

I.3. Problématique :

Les techniques d'imagerie que nous venons de voir ont apporté d'énormes perspectives aux médecins. On a bénéficié d'un grand gain de vitesse et d'efficacité. Or cette avancée technologique implique bien évidemment de nouvelles contraintes et de nouveaux challenges. En l'occurrence, bien lire et analyser attentivement une grande masse d'information, car il faut parcourir de longues séquences d'images prise dans plusieurs angles et détecter les anomalies et d'éventuelles pathologies. Cela demande une grande force de concentration. Les résultats d'analyse d'image ne sont pas objectifs et dépendent directement du praticien.

Répondre à ces contraintes et défis, est devenu la motivation première des chercheurs. En essayant de mettre en place divers systèmes, dans l'optique de tirer le plein bénéfice de ces technologies d'imagerie et apporter un bon support au corps soignant. Cela fera gagner énormément de temps et d'énergie.

Cela revient à concevoir un système intelligent capable de simuler le raisonnement du médecin en se basant sur des programmes de traitement d'images et de reconnaissance de formes. Cependant, rien ne remplace l'intelligence humaine, le savoir-faire et l'expérience du médecin. Donc c'est à lui que reviendra la décision finale après consultation des résultats du système.

Notre travail s'inscrit dans cet esprit-là (l'aide à la décision). Il porte sur les techniques d'imagerie par endoscopie comme information initiale. Et plus précisément la coloscopie. Il est connu que le colon (le grand intestin) est l'organe le plus exposé aux polypes. Les polypes se trouvent généralement dans le système digestif. Ce sont des tissus anormaux ou étrangers qui apparaissent et qui peuvent être mortels, puisqu'ils ont la capacité de se métamorphoser et de faire naître un cancer, et par la suite et créer ainsi un grand dommage dans le corps humain. Les polypes sont clairement visibles par endoscopie

cependant, déterminer leur nature (polypes bénins ou malins) est un grand défi à relever, et c'est le but principal de notre travail.

Afin de concevoir notre système, nous avons besoin de traiter deux problèmes majeurs. Tout d'abord il faut déterminer notre zone d'intérêt dans l'image endoscopique, qui est la région contenant le polype. Ce qui se traduit en traitement d'image par la segmentation. Il faut savoir que cette étape est très importante car la performance du système en dépend fortement. Ensuite, il faut analyser la structure de la zone extraite (Polype) afin d'en extraire les caractéristiques et de déterminer sa nature. Cet objectif est atteint par analyse de la texture, qui nous donne une description numérique pouvant être exploitée grâce à un classifieur donné.

I.3.1. Segmentation :

La segmentation est une technique de traitement d'image, utilisée dans plusieurs problèmes liés à l'analyse, détection, et reconnaissance d'objets dans l'image. Elle vise à partitionner une image en plusieurs régions, permettant de cette manière à filtrer les régions ne contenant aucune information (appartenant à l'arrière-plan) et à extraire les régions possédant l'information voulue.

De nombreuses méthodes ont été proposées dans ce but. On peut les classifier en méthodes statistiques, géométriques, et par optimisation [8].

Les méthodes statistiques sont basées sur l'analyse de l'histogramme. La segmentation par détection des vallées est l'approche la plus simple à adopter. Ensuite de nombreuses études statistiques peuvent être calculées comme la variance (méthode de minimisation de la variance) ou l'entropie, afin de mieux exploiter les données de l'histogramme [9].

Les méthodes géométriques sont très utilisées pour segmenter une image. Elle se base sur la mesure de similarité ou dissimilarité (frontières) entre les pixels voisins. Et donc de les regrouper si ils répondent à un critère donné (similarité en niveau de gris). Parmi ces méthodes on cite la segmentation par croissance de régions [10] permettant d'accroître les région itérativement en joignant les pixels voisins répondant à un certain critère de similarité. Tandis que le partitionnement et fusion de régions, c'est une méthode récursive qui consiste à diviser l'image en plusieurs partitions et de fusionner ces dernières si elles ont les mêmes caractéristiques [11]. D'autres méthodes géométriques se basent également sur la détection des contours. Ces approches utilisent les opérateurs de détection de frontières pour déduire une segmentation de l'image. Comme l'opérateur du gradient, sobel, robert et aussi le modèle de Canny-Dérivée [9].

Les méthodes basées sur l'optimisation, cherchent à formuler le problème de segmentation, en fonctions mathématiques dans lesquelles on cherche à trouver un compromis entre les régions et les contours. Parmi les méthodes les plus connues, on trouve l'approche de Mumford-Shah [1] et la méthode des contours actifs [12].

I.3.2. Classification à base de texture

La classification est une technique intelligente, capable d'affecter un objet à une classe donnée, en analysant ses caractéristiques et en se basant sur des données déjà acquises lors de la phase d'apprentissage.

Parmi les méthodes de classification à base d'apprentissage supervisé, les machines à vecteur de support [13] sont très utilisées dans ce genre de problème. On trouve aussi les réseaux de neurones (ANN (Artificial Neural Network)) [14] et l'analyse discriminante linéaire [15].

De nombreuses méthodes sont aussi mise au point pour l'analyse de la texture, ayant pour but d'en extraire les caractéristiques. On peut les classer en trois types : méthodes statistiques comme la matrice des cooccurrences des niveaux de gris GLCM (Grey Level Cooccurrence Matrix) + les mesures de Haralick et al [16], Et la matrice des longueurs de plages des niveaux de gris GLRLM [17] (Grey Level Run Length Matrix)). Méthodes spatiaux-fréquentielles (ondelettes) comme Gabor [18], Haar, Hadamard [19], Daubechies [20]). Méthodes géométriques comme les motifs binaires locaux LBP [21], [22] (Local Binary Patterns)

I.3.3. Les polypes du colon

Les polypes représentent une croissance anormale du tissu au niveau de la muqueuse. Ce sont des tumeurs de petites dimensions saillies dans la lumière intestinale, sans préjuger de leur nature histologique, ils peuvent être pédiculés, sessiles ou plans. Et peuvent être aussi malignes ou bénignes.

Lorsqu'il s'agit d'une population de polypes (>10) on parle de **polypose**.

I.3.3.1. Classification morphologique

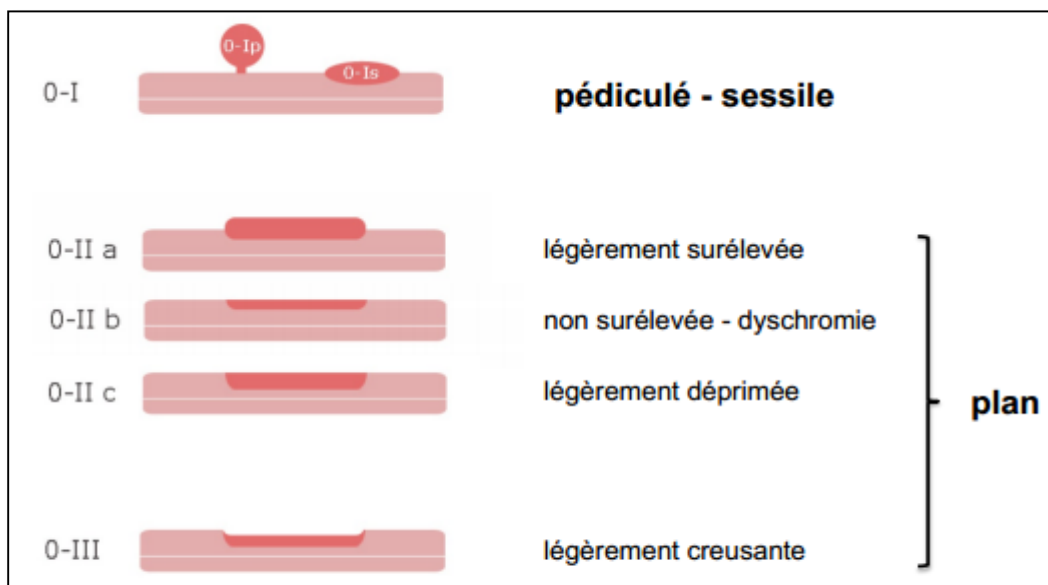


Figure 16 : les différentes formes de polypes

http://www.sfrnet.org/rc/org/sfrnet/htm/Article2011/20111209-144311-953/src/htm_fullText/fr/A.GARIOUD.pdf




Figure 17 : quelques photos endoscopiques des polypes du colon (a polype pédiculé b) polypes sessile c) polypes plan

http://www.sfrnet.org/rc/org/sfrnet/htm/Article/2011/20111209-144311-953/src/htm_fullText/fr/A.GARIOUD.pdf

I.3.3.2. Les cryptes de Kudo (Kudo Pit Patterns)

Après de longues études sur les tissus du colon, **Kudo et al** [23] ont réussi à mettre en place des modèles appelés **pit patterns**. Ces derniers ont pour but principal : la distinction entre deux grandes classes de polypes :

- **Polypes non néoplasique (ou bénins)** : ce sont des polypes qui n'évoluent pas, et donc ils sont moins dangereux et on peut les contrôler facilement et les arracher [24]. Ils peuvent être :

- **Hyperplasique** : Ce sont des polypes non-néoplasique (qui n'évoluent pas vers un cancer), ils sont les plus fréquents des polypes. Ils sont présents chez 20 à 35% des personnes âgées de plus de 50ans. Ils ont la forme sessile ne dépassant pas 1cm de taille.
- **Hamartomateux** : nous parlons de polypose hamartomateuse qui est visiblement, difficile à distingués des polypes Hyperplasiques. Ils comportent les polypes juvéniles qui touchent 1 à 2% des grands enfants et adolescents. Ils peuvent être héréditaires, dans ce cas le risque de se développer en cancer est de 10%. On trouve aussi les polypes du syndrome de **Peutz-jeghers** qui touchent l'intestin grêle.
- **Inflammatoire** : ces polypes sont issus des maladies inflammatoires chroniques comme la colite ulcéreuse de Crohn. Elle ne risque pas de se transformer en cancer, mais on peut les confondre avec les polypes adénomateux (précancéreux).

- **Polypes néoplasique** : contrairement aux bénins, ces polypes peuvent se transformer en cancer et sont capables de se propager dans la zone en question. Ce sont des polypes adénomateux, appelés aussi adénomes. Ils représentent 70% des polypes donnant naissance aux tumeurs cancéreuses dans le colon. Ces adénomes sont :

- **Tubuleux** : les plus fréquents qui représentent 65 à 87% des adénomes
- **Tubulo-villeux** : fréquence de 8% à 25% des adénomes.
- **Villeux** : fréquence de 5% à 10% des adénomes.

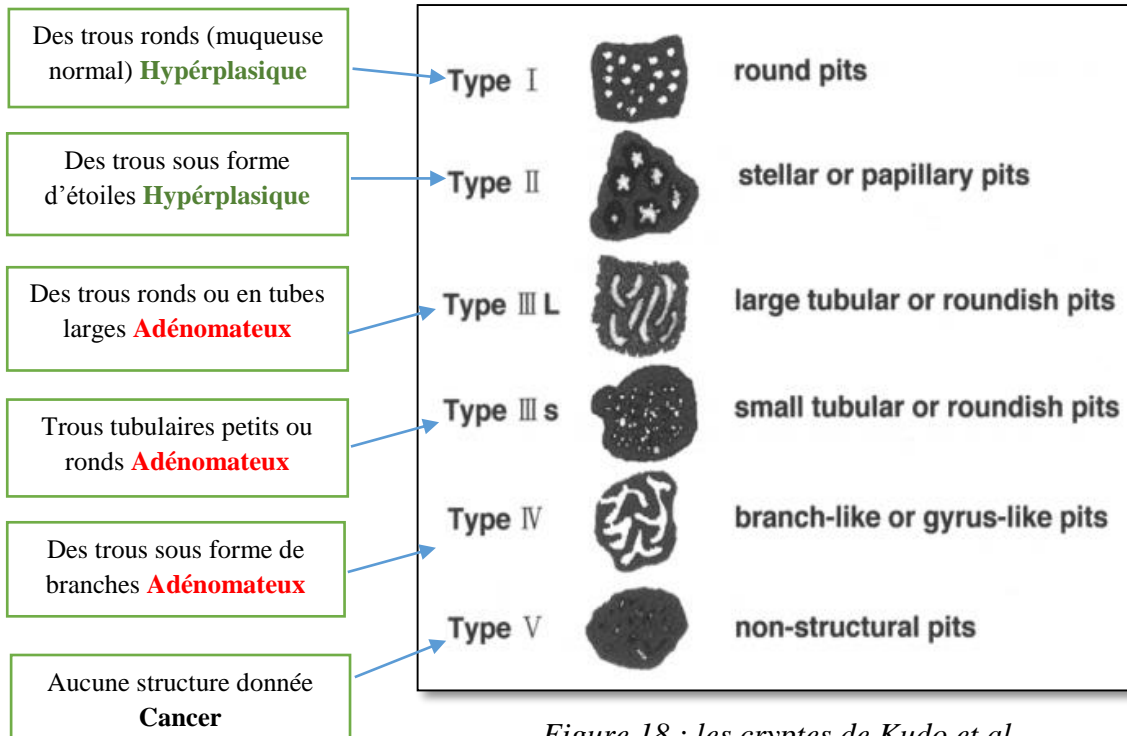


Figure 18 : les cryptes de Kudo et al
<https://www.ghrnet.org/index.php/JT/article/viewFile/775/889/3351>

I.3.3.3. Pit Patterns modifié par Hideki Mitooka

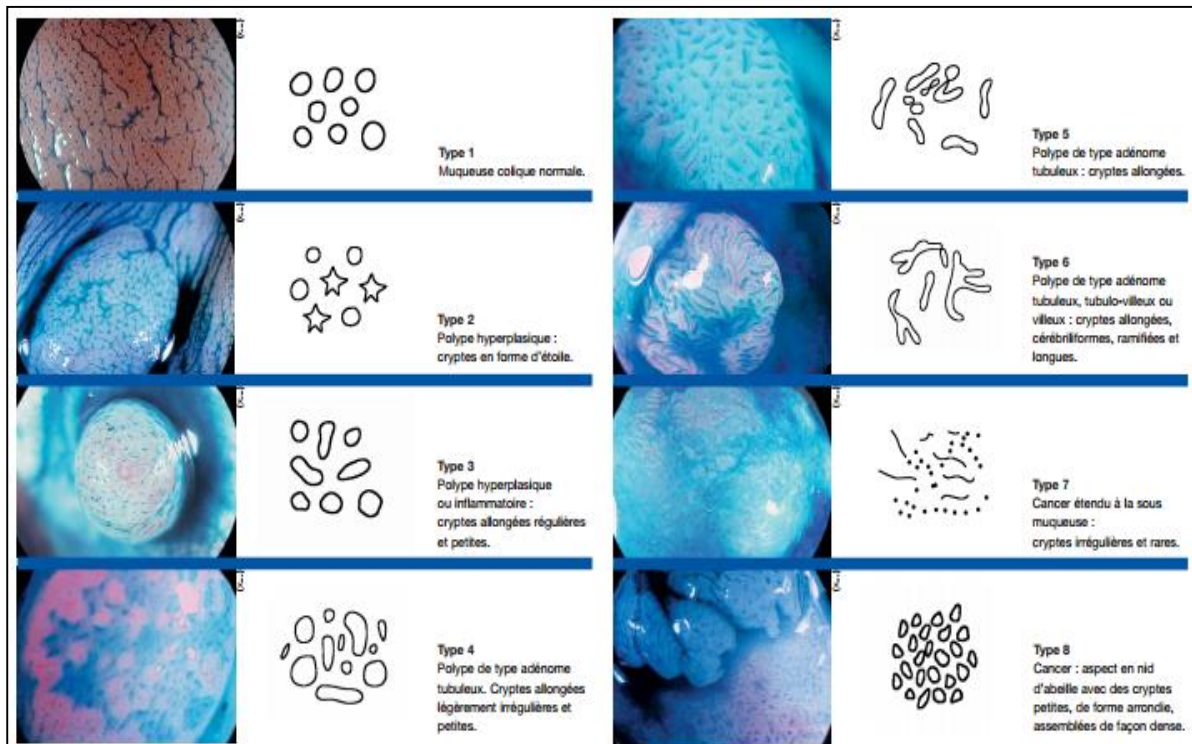


Figure 19 : les cryptes de Kudo modifié par H.Mitooka

http://www.sfrnet.org/rc/org/sfrnet/hm/Article/2011/20111209-144311-953/src/htm_fullText/fr/A.GARIOUD.pdf

Le professeur H.Mittoka, a réalisé une révision des pit patterns de Kudo en dérivant encore trois structures à partir des structures initiales. Nous remarquons que le type 1 et 2 sont les même que ceux de Kudo. Il a ajouté un autre type Hyperplasique (type 3) et un autre type cancer plus ou moins régulier (type 8).

I.3.4. Description du travail à réaliser

Notre travail traitera des images endoscopiques sans avoir recours à l'utilisation de la chromoendoscopie, ce qui représente un défi à relever pour concevoir un système intelligent capable de distinguer entre les polypes bénins et les cancers.

En se basant sur les notions vues précédemment, les différentes étapes à suivre sont schématisées dans la **Figure 20** qui suit :

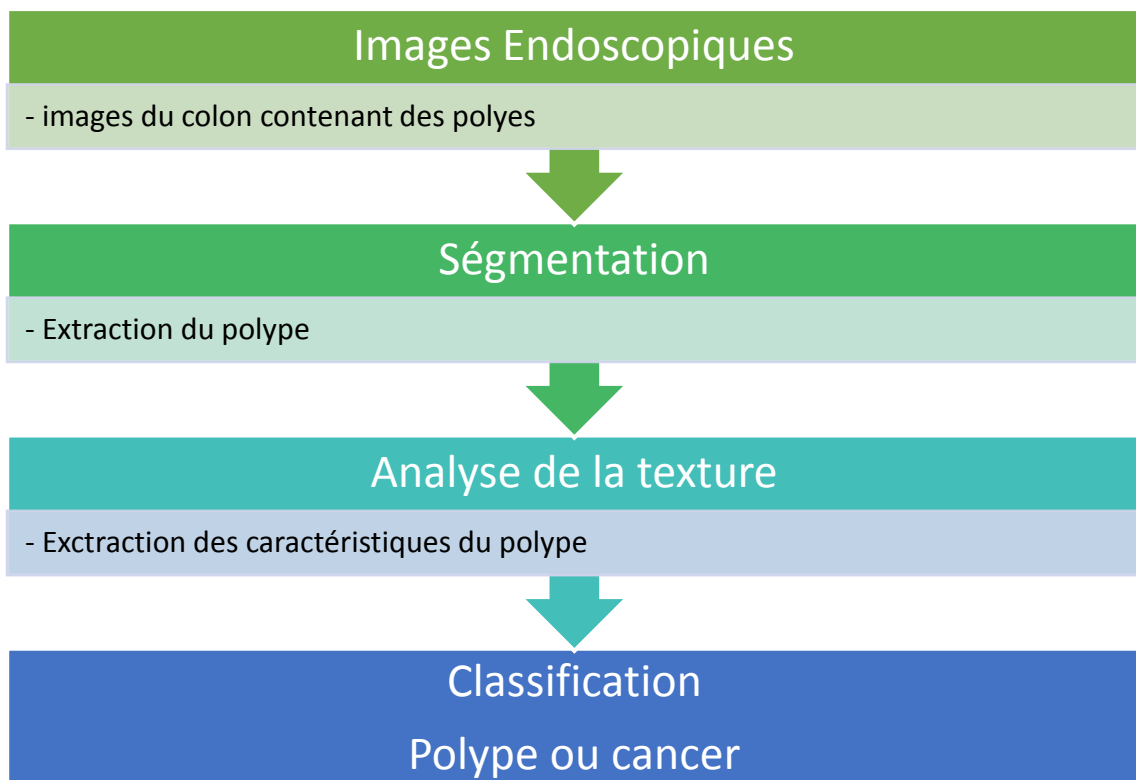


Figure 20 : Schéma global du système

Chapitre II

Etat de l'art

II.1. Introduction

Pour résoudre le problème évoqué dans la problématique, notre objectif vise principalement la recherche d'une méthode d'analyse de texture, fiable et assez pointue pour arriver à extraire les bon caractéristiques de chaque image issue d'une classe. Cette phase constitue un facteur déterminant de la robustesse de la méthode à adapter.

Au cours de notre recherche, nous avons trouvé énormément de méthodes de classifications se basant sur les descripteurs de textures préalablement cités, traitant de multiples problèmes dans de différents domaines. Et donc nous avons sélectionné les méthodes qui peuvent nous intéressé vis-à-vis leur compatibilité avec notre besoin.

II.2. Analyse de texture pour la Segmentation

Les polypes sont caractérisés par une texture différente de celle de la muqueuse normale. Ils ont aussi une forme morphologique permettant de les localiser dans une image endoscopique et de les extraire par la suite. On peut aussi les distinguer par leur niveau très élevé de la composante rouge, par rapport à la muqueuse normale, qui est dû à une inflammation.

Notre recherche sur les méthodes de segmentation s'est basée sur les critères cités. Plusieurs articles traitent le même problème mais dans différents domaines que le médical, comme la détection automatique du Mango [25], en utilisant l'analyse de la texture, en calculant la différence entre l'intensité maximale et minimale dans une fenêtre de l'image, et puis la détection de la forme du Mango en utilisant la transformée aléatoire de Hough pour la détection des ellipses. L'utilisation des contours actifs en les fusionnant avec les descripteurs de texture est aussi une approche très efficace pour la segmentation d'images texturées, par exemple l'utilisation de l'ACWE (Active Contour Without Edges) avec les descripteurs de Gabor et la GLCM (Grey Level Cooccurrence Matrix) [26]. L'utilisation de la méthode de coupure de graph (Fenzens walb [27]) comme dans [28] pour la détection des glomérules dans une biopsie rénale. Puis dans le même problème que le nôtre (Mamonov et al) [29] la détection des polypes en analysant la texture avec l'algorithme de (Buades et al) [30] suivi de la convolution non-linéaire et puis l'extraction des polypes à base des critères géométriques.

II.3. Analyse de la texture pour la classification

Les analyseurs de texture utilisés pour la segmentation sont également employés pour les problèmes de classification d'images à base de leurs caractéristiques texturales.

Dans [31], les auteurs ont proposé une approche ayant pour but la classification des bois durs en se basant sur des images microscopiques, permettant ainsi une bonne vision de la texture de chaque spécimen. Pour l'extraction des caractéristiques, ils ont fusionné deux approches : la décomposition de l'image à l'aide de l'ondelette de daubéchies sur 7 niveaux. Cette méthode a pour but de répartir les caractéristiques de l'image sur plusieurs composants sans redondance de l'information. Ainsi les caractéristiques deviennent plus claires et peuvent être extraites facilement. Puis ils ont procédé à l'extraction des caractéristiques des composants issues de daubéchies, en testant chacun des motifs binaires locaux suivant :

LBP, LBP^{ri} , LBP^{u2} , LBP^{riu2} , LBP^{HF} , $CLBP^{u2}$. La méthode a été nommée Multi Resolution Local Binary Patterns (MRLBP).

Une version modifiée de la décomposition par ondelette de Haar, a été proposée dans [32]. Le principe est le même que dans [31] ayant pour but la détection de la maladie de l'ostéoporose qui touche principalement les os trabéculaires, par analyse de la texture. Dans cet article les chercheurs ont introduit un nouveau descripteur déduit de la décomposition en ondelettes. Il s'agit de l'ondelette **Chef** (Wavelet Leader). Ils ont montré mathématiquement que l'ondelette chef contient le maximum d'informations issues des images de hautes fréquences.

Pour l'extraction des caractéristiques, deux méthodes statistiques ont été expérimentées, la GLCM (39) avec la mesure de l'énergie et GLRLM avec la mesure de la non-uniformité pour les orientations $[0^\circ 45^\circ 90^\circ 135^\circ]$. Ils ont mesuré la performance sur chacun des composants de l'ondelette à savoir :

CA : Composant d'Approximation.

CH : Composant Horizontal.

CV : Composant Vertical.

CD : Composant Diagonal.

Et puis l'ondelette chef.

Finalement ils ont constaté une amélioration moyenne de 5% de robustesse en utilisant l'ondelette chef ainsi que l'invariance des performances par rotation.

Un autre problème a été discuté en combinant les GLCM et les LBP. Il s'agit de classifier les feuilles du thé pour permettre à un système de détecter la nature de chaque feuille et de la traiter correctement. Il est connu que le descripteur GLCM est très robuste pour l'analyse de la texture mais très coûteux au niveau du temps surtout pour ce genre d'applications temps réel. Donc ils ont pensé à introduire le descripteur LBP permettant de représenter une fenêtre de l'image par une valeur décimale, ce qui réduit sa dimension. Par la suite l'utilisation du GLCM devient très efficace. En combinant les deux descripteurs, ils ont obtenu de meilleures performances au niveau de la classification des feuilles.

Etat de l'art

Le filtre de Gabor est également très utilisé pour la classification, et peut être amélioré en le combinant avec l'invariance, comme dans la classification des tissus gastro-entérologiques en se basant sur leurs images chromoendoscopiques (CH) et celles à bandes spectrales étroites (NBI) [33]. L'idée de l'invariance est de déduire la réponse impulsionnelle d'une image orientée avec un angle θ ou subissant un changement d'échelle, en se basant sur la réponse de l'image originale (sans rotation ou changement d'échelle). Ils ont déduit par la suite que l'invariance peut être achevée en appliquant l'autocorrélation.

Ce sont les méthodes sur lesquelles nous avons basé notre documentation. Maintenant nous allons découvrir quelques descripteurs utilisés pour l'analyse de la texture.

II.4. Descripteurs de texture

L'image texturée constitue toujours un défi à relever dans le traitement d'images. Il s'agit de détecter des zones ayant une constellation particulière de pixels, et de les extraire facilement par la suite. La **Figure 21** nous montre clairement la différence de texture entre celle du polype et celle de son entourage.




Figure 21 : Polype avec une texture différente de la muqueuse normale

Dans cette partie nous allons aborder en détail quelques méthodes que nous avons citées auparavant :

II.4.1. Le filtre de Gabor

C'est un filtre linéaire conçu par **Dénis Gabor** permettant de simuler mathématiquement le fonctionnement des cellules simples du cortex visuel primaire V1, chez le système visuel des mammifères.

Gabor est un filtre constitué du produit d'une gaussienne et un exponentiel complexe, défini comme suit :

$$g(x, y, \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + y'^2 \gamma'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi \frac{x'}{\lambda} + \psi\right)\right) \quad (1)$$

Avec : $x' = x \cos \theta + y \sin \theta$ et $y' = -x \sin \theta + y \cos \theta$

Entrées de la fonction :

x, y : les coordonnées de chaque pixel.

λ : longueur d'onde du filtre

θ : orientation du filtre

ψ : la phase de l'onde

σ : l'écart type

γ : rapport d'aspect spatial

Bien que le filtre de Gabor soit très ancien, il demeure l'un des meilleurs descripteurs utilisés dans de multiples problèmes comme la reconnaissance de formes : Reconnaissance biométrique du visage [34] appliquée à l'entreprise afin de renforcer la sécurité des données. Gabor est aussi utilisé pour la segmentation d'images en régions homogènes [18] de point de vue texture. Et plein d'autres applications.

Fonctionnement :

En se basant sur la fonction (1), on génère un certain nombre de filtres appelés (filter bank), en variant ses paramètres notamment θ , λ et σ . Ce qui nous permet de capturer toute sorte de texture.

Pour obtenir des réponses impulsionnelles des pixels de l'image vis-à-vis les filtres. On la soumet à un filtrage linéaire par convolution. Ainsi on obtient les différentes caractéristiques de chaque pixel.

La **Figure 22** représente un ensemble de filtres en variant l'orientation et l'échelle [34]. Pour obtenir huit orientation, on allons de 0° avec un pas de $\pi/8$. L'écart-type doit être proportionnel à la fréquence du filtre ($f = 1/\lambda$).

Etat de l'art




Figure 22 : Exemple d'un ensemble de filtres avec 6 échelles et 8 orientations (48 filtres).

Après avoir filtré un polype dont la texture est plus ou moins claire **Figure 23**, nous pouvons à présent analyser le résultat et utiliser les caractéristiques obtenues pour les appliquer dans différentes tâches.

Pour N filtres utilisés, on obtient N images filtrées et donc un vecteur caractéristique de N dimensions pour chaque pixel.

On remarque à travers les résultats obtenues que l'information pertinente ne figure pas dans toutes les réponses que nous avons obtenues. On en déduit que le design des filtres de Gabor (choix des paramètres) dépend fortement du types d'image à analyser, et de l'emplacement de l'information à extraire.

A travers ce même exemple, nous pouvons déduire aussi que le filtre de Gabor est un bon détecteur de contours, puisque nous remarquons clairement l'allure du polype. Et Donc il peut servir comme operateur de base pour ce problème.

De ce qui a été dit, Gabor représente un moyen efficace pour la distinction entre le polype cancéreux et non-cancéreux. Car vu la différence de leur textures, le filtre de Gabor aura forcément des réponses assez différentes. Sous condition de bien choisir les paramètres afin d'obtenir des caractéristiques les plus représentatives de la structure.




Figure 23 : Extraction des caractéristiques texturales d'un polype avec les filtres de Gabor

II.4.2. Les ondelettes

La décomposition en ondelettes est une technique très intéressante. Elle consiste à décomposer n'importe quel signal en des sommes pondérées d'ondelettes issues d'une même ondelette mère. Ces ondelettes subissent un changement d'échelle (**Figure 25**) ou translation (**Figure 24**) afin de capturer toute sorte de signal à un instant donné. Cette technique est utilisée pour diverses applications, à savoir la compression des images (compression JPEG2000 [35]), détections des contours [36], et aussi pour le traitement du bruit.

Supposant que, $\psi(t)$ est l'ondelette mère.

Sa version dilatée et traduite est créée de cette manière :

$$\psi_{s,t} = \frac{1}{\sqrt{2}} \psi\left(\frac{x-t}{s}\right) \quad (2)$$

Avec :

s : le facteur de dilatation

t : le facteur de translation

Le formalisme de l'ondelette est mis en place afin de combler les limites de la transformée de Fourier, étant donné que cette dernière nous permet uniquement la représentation des informations dans le domaine fréquentiel, en ignorant leur localisations dans le domaine spatial (cas de l'image) ou temporel (cas du son). Or, Parfois on a besoin des deux informations au même temps.

Etat de l'art




Figure 24 : translation de l'ondelette. A gauche $\psi(t)$. A droite $\psi(t - k)$




Figure 25 : Changement d'échelle d'une ondelette

Transformée discrète en ondelettes :

Contrairement à la transformée continue (l'intégral), la DWT (Discret Wavelet Transform) est plus rapide en calcul, puisqu'elle prend des échelles en puissance de 2 au lieu de calculer tous les cas possibles. Donc les ondelettes filles sont exprimées ainsi :

$$\psi_{s,t}(x) = 2^{s/2} \psi(2^s x - t) \quad (3)$$

Un signal $f(n)$ peut être représenté avec une somme pondérée d'ondelettes $\psi(n)$ plus une approximation $\varphi(n)$

$$f(n) = \frac{1}{\sqrt{M}} \sum_t W_\varphi(s_0, t) \varphi_{s_0,t}(n) + \frac{1}{\sqrt{M}} \sum_{s=s_0}^{\infty} \sum_t W_\psi(s, t) \psi_{s,t}(n) \quad (4)$$

Avec :

$$W_\varphi(s_0, t) = \frac{1}{\sqrt{M}} \sum_t f(x) \varphi_{s_0,t}(x) \quad \text{Coefficients d'approximation} \quad (5)$$

Etat de l'art

$$\text{et } W_\psi(s, t) = \frac{1}{\sqrt{M}} \sum_t f(x) \psi_{s_0, k}(x) \quad \text{Coefficients des détails (6)}$$

Ce sont les deux sortes de signaux permettant la décomposition et la reconstruction du signal initial.

Pour le traitement de la texture, nous avons besoin de connaître la localisation des pixels dans l'image et leur relation avec leurs voisinages, ainsi que leurs fréquences dans l'image, donc les ondelettes sont très adaptées pour ce genre de problème.

Parmi les ondelettes les plus connues on cite :

- Ondelette de Morlet (Première ondelette créée).
- Ondelette de Gabor
- Ondelette de Haar
- Ondelette de Daubéchies.

II.4.2.1. L'ondelette de Haar

L'ondelette de Haar est la plus simple des ondelettes qui existent. Elle permet la décomposition d'un signal de résolution n , à plusieurs ondes de résolution inférieure. Plusieurs décompositions peuvent avoir lieu, et s'effectuent itérativement.

La fonction mère de Haar est décrite ainsi :

$$\psi(x) = \begin{cases} 1 & \text{si } 0 \leq x < \frac{1}{2} \\ -1 & \text{si } \frac{1}{2} \leq x < 1 \\ 0 & \text{sinon} \end{cases} \quad (7)$$

Avec la fonction d'approximation :

$$\phi(x) = \begin{cases} 1 & \text{si } 0 \leq x < 1 \\ 0 & \text{sinon} \end{cases} \quad (8)$$

Les ondelettes filles doivent être orthogonales avec l'ondelette mère, et peuvent être calculées en variant l'échelle et la translation par les expressions données par :

$$\psi_{a,b}(x) = 2^{a/2} \psi(2^a x - b) \quad \text{et} \quad \phi_{a,b}(x) = 2^{a/2} \phi(2^a x - b)$$

Etat de l'art

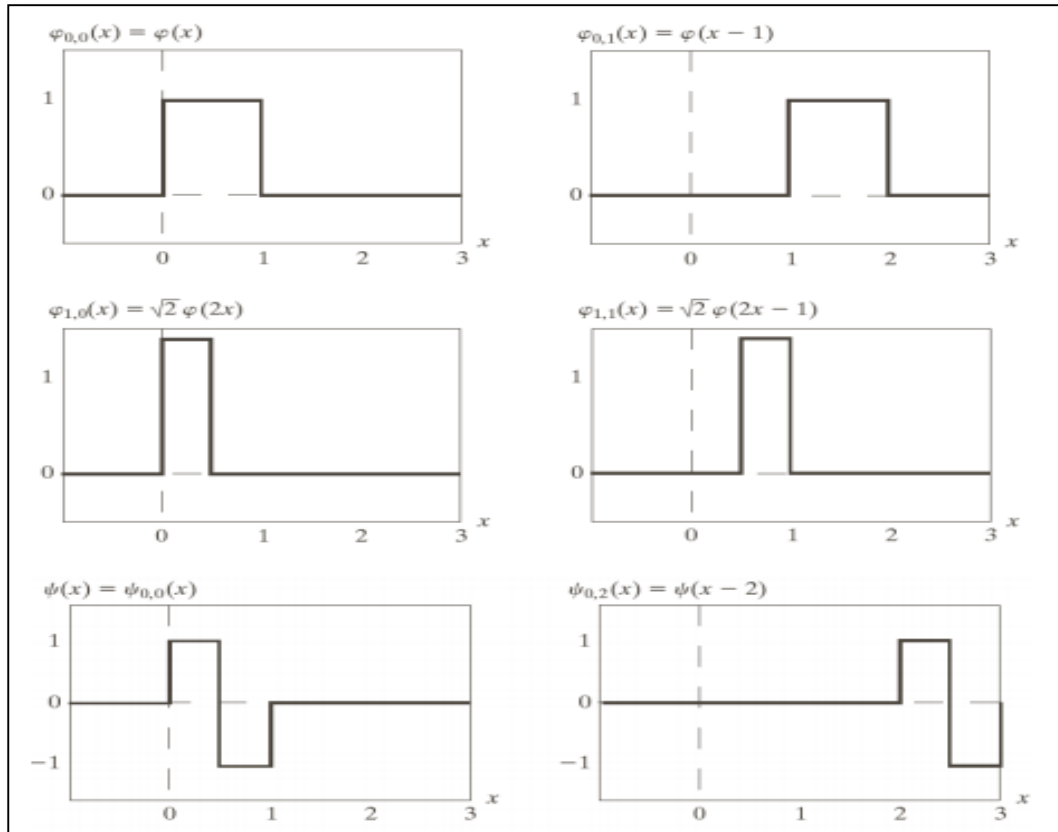


Figure 26 : les ondelettes et leurs fonctions d'approximation

Application dans le domaine unidimensionnel :

Supposant qu'on veut décomposer un vecteur V de résolution 4, ayant pour valeurs $V = [9 \ 7 \ 3 \ 5]$ avec l'ondelette mère, en effectuant deux itérations.

Décomposition 1 :

- On multiplie chaque paire de valeurs du vecteur par $[1 \ -1]$ de l'ondelette mère (7) et on divise par la longueur d'onde :

$$((9*1) + (7*(-1)))/2 = 1 \text{ et } ((3*1) + (5*(-1)))/2 = -1 \quad \text{R1}$$

- On effectue le même calcul sur $[1 \ 1]$ de la fonction d'approximation de l'ondelette mère (8) :

$$(9 + 7)/2 = 8 \text{ et } (3 + 5)/2 = 4 \quad \text{R2}$$

Le vecteur d'approximation obtenu dans R2 est $A = [8, 4]$ avec une résolution réduite à 2. En revanche, si nous voulons reconstruire V nous avons besoin des coefficients obtenus dans R1 $B = [1, -1]$ vecteur de détails.

Décomposition 2 :

En recommence le même calcul sur le vecteur d'approximation, et on obtient deux valeurs de résolution 1:

Etat de l'art

- Valeur d'approximation : $(8 + 4)/2 = [6]$.
- Valeur de détail : $(8 - 4)/2 = [2]$

Résolution	Approximation	Détail
4	[9 7 3 5]	
2	[8 4]	[1 -1]
1	[6]	[2]

Finalement la décomposition de [9 7 3 5] est donnée par [6 2 1 -1].

On peut reconstruire facilement le vecteur initial en effectuant des additions et soustraction entre les approximations et les détails.

D'après l'exemple on constate que la majorité de l'information est contenu dans le vecteur d'approximation → la fonction d'approximation agit comme un filtre passe-bas avec une réduction de la résolution. Par contre le vecteur de détails possède les informations qui aident à la reconstruction du signal → la fonction de l'ondelette agit comme un filtre passe-haut ne laissant passer que les hautes fréquences.

- **Matrice de Haar :**

Afin de faciliter le calcul des coefficients d'approximation et de détail, l'ondelette mère de Haar est représentée avec une matrice :

$$H = \begin{bmatrix} 1/2 & 1/2 \\ 1/2 & -1/2 \end{bmatrix}$$

La première ligne permet de calculer l'approximation (filtrage passe-bas). La deuxième ligne permet de calculer les détails.

Cette matrice est adaptée à la résolution du signal initial :

$$H_8 = \begin{bmatrix} 1/2 & 1/2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1/2 & 1/2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1/2 & 1/2 \\ 1/2 & -1/2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1/2 & -1/2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1/2 & -1/2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1/2 & -1/2 \end{bmatrix} * \begin{bmatrix} v_1 \\ v_2 \\ v_3 \\ v_4 \\ v_5 \\ v_6 \\ v_7 \\ v_8 \end{bmatrix} = \begin{bmatrix} \frac{v_1+v_2}{2} \\ \frac{v_3+v_4}{2} \\ \frac{v_5+v_6}{2} \\ \frac{v_7+v_8}{2} \\ \frac{v_1-v_2}{2} \\ \frac{v_3-v_4}{2} \\ \frac{v_5-v_6}{2} \\ \frac{v_7-v_8}{2} \end{bmatrix} y$$

Bloc d'approximation
Bloc des détails

Figure 27 : décomposition d'un signal à l'aide de la matrice de Haar

Etat de l'art

Les 4 premières lignes représentent le filtrage passe-bas et le reste représente le filtrage passe-haut.

- **Application sur l'image (2D) :**

Pour appliquer l'ondelette de Haar sur une image il suffit d'étendre le calcul sur les trois axes :

- Vertical
- Horizontal
- Diagonal

Afin de faciliter le calcul on peut se servir des filtres suivants :




Figure 28: Filtre permettant la décomposition de l'image : ϕ^0 PB, ψ_1^0 : PHH, ψ_2^0 : PHV, ψ_3^0 : PHD

PB : passe-bas.
PH : passe-haut.




Figure 29 : Décomposition de l'image en ondelettes de Haar. a) : Approximation (filtrage passe-bas) b) : détails horizontaux. c) détails verticaux. d) détails diagonaux

II.4.2.2. L'ondelette de Daubéchies

L'ondelette de daubéchies [37] est une version avancée de la famille Haar créée par **Ingrid Daubéchie**. Son principe de décomposition est le même que celui de Haar, (filtrage passe-haut et passe-bas). La seule différence réside dans le choix des coefficients pour calculer l'image d'approximation et ceux permettant de calculer les images de détails.

Les ondelettes de daubéchies d'ordre N est noté dbN. Chaque ondelette d'ordre N possède des coefficients particuliers pour le calcul.




Figure 30 : Exemple d'ondelette de daubéchies

NB : db1 est l'ondelette de Haar

L'ondelette la plus utilisée est celle d'ordre 4 (db4) dont les coefficients sont définis par :

- Coefficient d'échelle (filtrage passe-bas):
 - $h_0 = \frac{1+\sqrt{3}}{4\sqrt{2}}$
 - $h_1 = \frac{3+\sqrt{3}}{4\sqrt{2}}$
 - $h_2 = \frac{3-\sqrt{3}}{4\sqrt{2}}$
 - $h_3 = \frac{1-\sqrt{3}}{4\sqrt{2}}$
- Coefficient de l'ondelette (filtrage passe-haut):
 - $g_0 = h_3$
 - $g_1 = -h_2$
 - $g_2 = h_1$
 - $g_3 = -h_0$

La décomposition d'un signal par db4 est effectuée par une simple multiplication matricielle :

Pour un signal de résolution 8 on a:

Etat de l'art

$$\begin{pmatrix} h_0 & h_1 & h_2 & h_3 & 0 & 0 & 0 & 0 \\ g_0 & g_1 & g_2 & g_3 & 0 & 0 & 0 & 0 \\ 0 & 0 & h_0 & h_1 & h_2 & h_3 & 0 & 0 \\ 0 & 0 & g_0 & g_1 & g_2 & g_3 & 0 & 0 \\ 0 & 0 & 0 & 0 & h_0 & h_1 & h_2 & h_3 \\ 0 & 0 & 0 & 0 & g_0 & g_1 & g_2 & g_3 \\ h_0 & h_1 & 0 & 0 & 0 & 0 & h_2 & h_3 \\ g_0 & g_1 & 0 & 0 & 0 & 0 & g_2 & g_3 \end{pmatrix} * \begin{pmatrix} S_0 \\ S_1 \\ S_2 \\ S_3 \\ S_4 \\ S_5 \\ S_6 \\ S_7 \end{pmatrix} = \begin{pmatrix} E_0 \\ D_0 \\ E_1 \\ D_1 \\ E_2 \\ D_2 \\ E_3 \\ D_3 \end{pmatrix}$$

Matrice db4

Signal

Sortie

Puisque les filtre passe-haut et bas s'alternent dans la matrice, les sorties auront la même organisation :

Les valeurs d'approximation (ou d'échelle) sont [E0 E1 E2 E3] et les valeurs de détail sont : [D0 D1 D2 D3].

En appliquant la décomposition une deuxième fois sur les valeurs d'approximation on obtient :

$$\begin{pmatrix} h_0 & h_1 & h_2 & h_3 \\ g_0 & g_1 & g_2 & g_3 \\ h_0 & h_1 & h_2 & h_3 \\ g_0 & g_1 & g_2 & g_3 \end{pmatrix} * \begin{pmatrix} E_0 \\ E_1 \\ E_2 \\ E_3 \end{pmatrix} = \begin{pmatrix} E'0 \\ D'0 \\ E'1 \\ D'1 \end{pmatrix}$$

Matrice db4

Valeur d'échelle

Sortie

Les valeurs d'approximation sont : [E'0 E'1] et les valeurs de détail sont [D'0 D'1]. La décomposition s'arrête à ce stade par manque de valeurs d'approximation.

Pour le calcul d'un signal 2D. Il faut effectuer le même calcul dans les directions horizontales, verticales, et diagonales.

II.4.3. GLCM (Matrice des cooccurrences des niveaux de gris)

C'est un descripteur très performant lorsqu'il s'agit de l'analyse de la texture. Il a été introduit par Haralick et al [16] . C'est une méthode statistique basée sur des mesures calculées à partir d'une matrice appelée matrice de cooccurrences des niveaux de gris.

Cette matrice contient le nombre d'occurrences de chaque paire de pixels dans l'image en tenant compte des paramètres suivants :

- Les intensités de chaque paire (i, j)
- Leurs distances suivants x et y
- Les niveaux de gris (256, 128, 64...) qui représentent la taille de la matrice.

$$G_{\Delta x, \Delta y}(i, j) = \sum_{p=1}^n \sum_{q=1}^m \begin{cases} 1, \text{ Si } I(p, q) = i \text{ et } I(p + \Delta x, q + \Delta y) = j \\ 0, \text{ Sinon} \end{cases} \quad (9)$$

En pratique $\Delta x = \Delta y = d$ (Figure 31), et donc pour générer une GLCM, il faut fixer la distance entre les paires de pixels et leurs orientations, et faire le calcul Figure 32

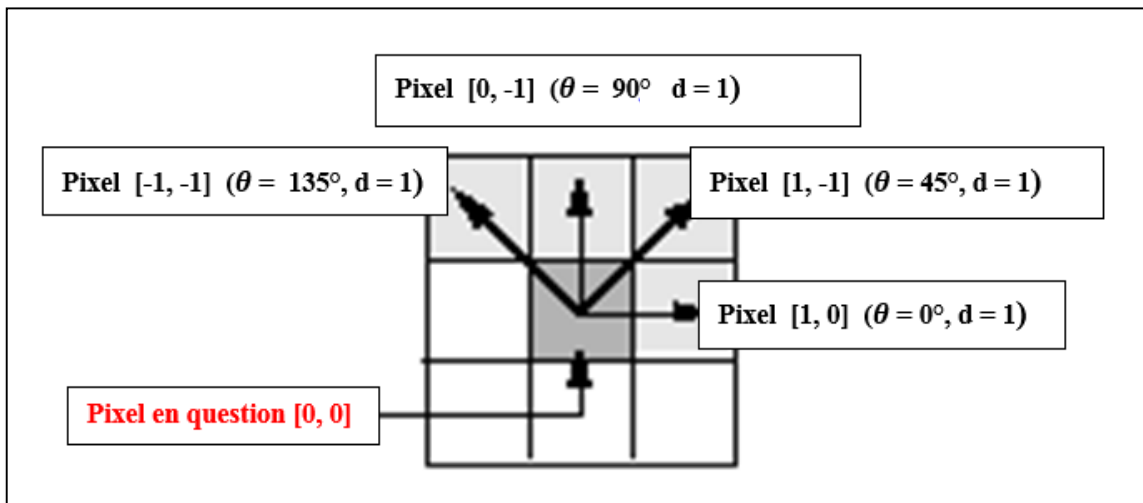


Figure 31 : les voisins d'un pixel central $[0,0]$ selon une distance et orientation données ($d=1$ voisins adjacents et $\theta = [0, 45^\circ, 90^\circ, 135^\circ]$)

Pour chaque orientation et distance fixées, nous calculons une matrice de cooccurrence.

A partir de la matrice générée on peut effectuer des mesures statistiques qui nous donnerons des informations sur les caractéristiques de l'image.

Etat de l'art

- Exemple :

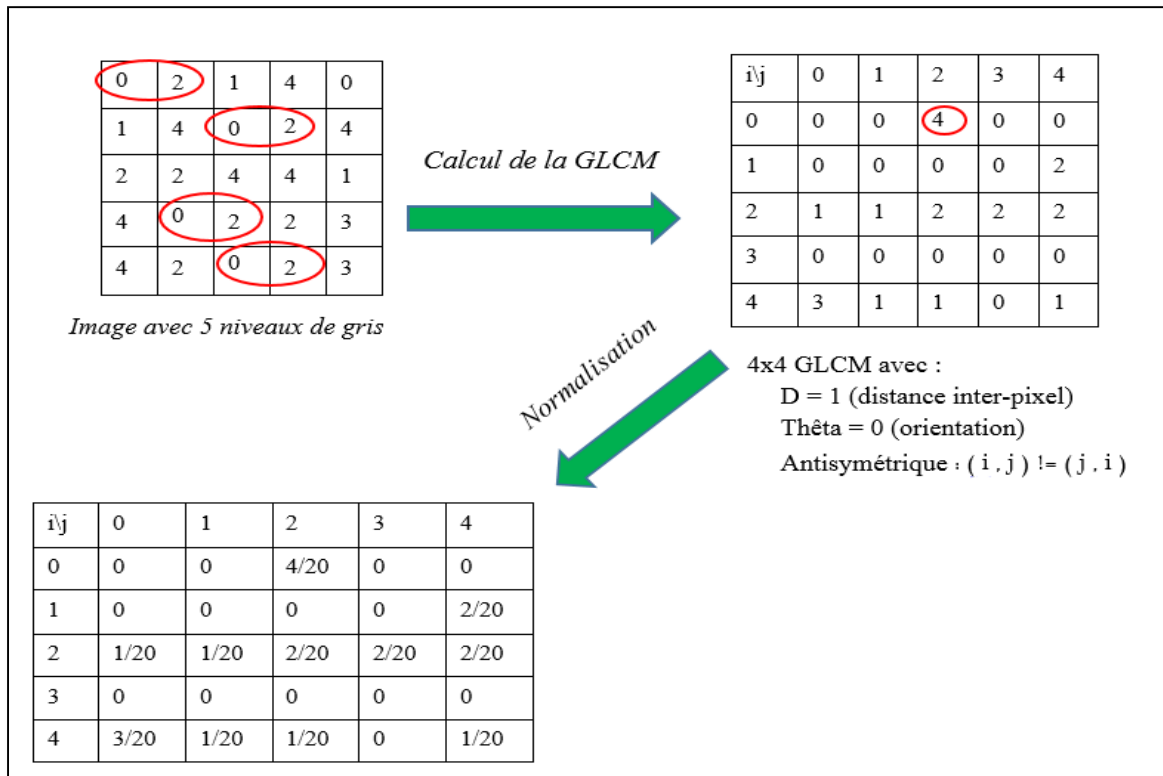


Figure 32 : Calcul de la matrice des cooccurrences d'une image à 5 niveaux de gris

Les mesures statistiques de Haralick et al :

$P(i, j)$: Le nombre de cooccurrences des pixels i et j (lu directement de la matrice).

G : niveau de gris choisi (taille de la GLCM).

$$P_{x+y}(k) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j) \text{ tq } (i + j) = k \text{ et } k = 0, 1, \dots, 2(G - 1)$$

$$P_x(i) = \sum_{j=0}^{G-1} P(i, j) \text{ et } P_y(j) = \sum_{i=0}^{G-1} P(i, j)$$

$$\mu_x = \sum_{i=0}^{G-1} iP_x(i) \quad , \quad \mu_y = \sum_{j=0}^{G-1} jP_y(j) \quad \text{et} \quad \mu = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} iP(i, j)$$

Etat de l'art

$$\sigma_x^2 = \sum_{i=0}^{G-1} (i - \mu_x) P_x(i) \quad , \quad \sigma_y^2 = \sum_{j=0}^{G-1} (j - \mu_y) P_y(j)$$

a. SMA (Second Moment Angulaire) :

$$SMA = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i,j)^2$$

b. Contraste:

$$Contraste = \sum_{n=0}^{G-1} n^2 \left\{ \sum_{i=0}^G \sum_{j=1}^G P(i,j) \right\}, \quad |i-j| = n$$

c. Dissimilarité :

$$Dissimilarité = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i,j) |i-j|$$

a. Corrélation :

$$Correlation = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{\{i \times j\} \times P(i,j) - \{\mu_x \times \mu_y\}}{\sigma_x \times \sigma_y}$$

b. Variance :

$$Variance = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i - \mu)^2 P(i,j)$$

c. Homogénéité

$$Homogeneite = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{P(i,j)}{1 + (i-j)^2}$$

Etat de l'art

d. Moyenne de sommes :

$$MS = \sum_{i=2}^{2G} iP_{x+y}(i)$$

e. Variance des sommes :

$$VS = \sum_{i=2}^{2G} (i - ENTS)^2 P_{x+y}(i)$$

f. Entropie des sommes :

$$ENTS = - \sum_{i=2}^{2G} P_{x+y}(i) \log(P_{x+y}(i))$$

g. Entropie :

$$ENT = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i,j) \log(P(i,j))$$

h. Variance des différences :

$$VD = \text{variance}(P_{x+y})$$

i. Entropie des différences :

$$ENTD = - \sum_{i=0}^{G-1} P_{x+y}(i) \log(P_{x+y}(i))$$

Extraction des caractéristiques de l'image :

Maintenant que nous connaissons toutes les notions qu'il nous faut, reste à savoir comment les utiliser :

Pour extraire les caractéristiques d'une image il faut tout d'abord fixer les différents paramètres nécessaires :

Etat de l'art

1. Le niveau de gris G (255 par défaut sinon procéder à la quantification).
2. Les différents angles et distances à adapter pour la mesure.
3. Choisir les caractéristiques de Haralick et al à mettre en place pour l'analyse.
4. Pour chacun des paramètres fixés nous calculons l'image caractéristique résultante comme suit :
 - Afin d'obtenir l'information locale, on ne va pas appliquer la GLCM pour toute l'image, mais on va l'appliquer plusieurs fois sur des fenêtres glissantes **Figure 33**.
 - Ensuite nous calculons l'une des mesures statistiques de Haralick et al vu précédemment sur cette fenêtre GLCM, et on affecte le résultat au pixel central.

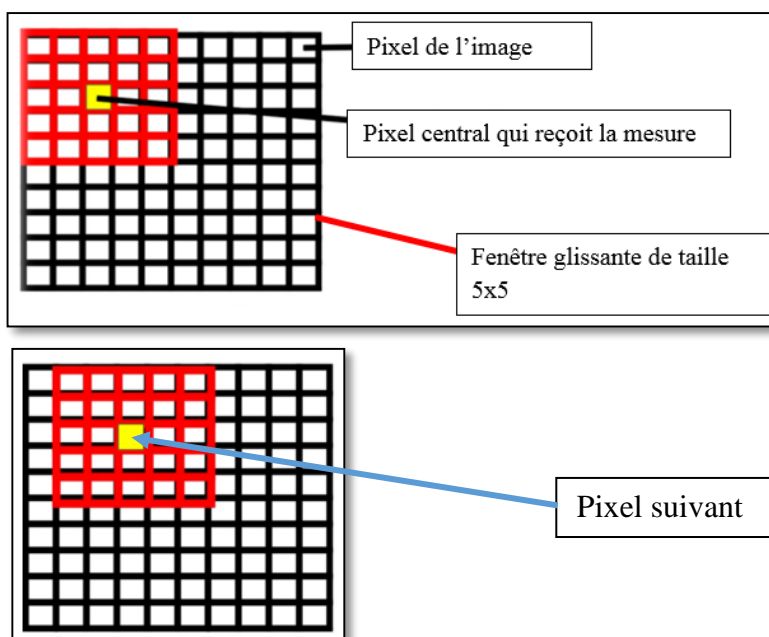


Figure 33 : Méthode de calcul de l'image filtré par la GLCM

Exemple :




Figure 34 : Image filtré par GLCM de distance égale à 1. Résultats des mesures Haralick : Les colonnes représentent les mesures prise respectivement : Contraste, Dissimilarité, et homogénéité. Les lignes représentent les orientations : $0^\circ, 45^\circ, 90^\circ, 135^\circ$

II.4.4. Les motifs binaires locaux (Local Binary Patterns)

L'opérateur LBP a été proposé par Wang et He [9] comme un nouveau modèle de description de texture. Ce descripteur est basé sur l'unité de texture : ils ont attribué à chaque pixel une valeur qui le caractérise par rapport à son voisinage.

Les expériences faites dans [21], [22] ont prouvé ses performance en classification et surtout sa simplicité de calcul qui fait de lui un choix très juste dans des reconnaissances en temps réel.

Cette méthode se base sur le seuillage et la représentation binaire. Elle permet de caractériser chaque pixel en effectuant un seuillage sur chacun de ses voisins (**Figure 35**) en leur donnant une valeur binaire. Cette valeur est considérée comme une caractéristique du pixel en question. Ce qui nous permet par la suite de construire un histogramme d'occurrence de ces valeurs afin de déterminer les motifs qui se répètent.

Ce descripteur a connu plusieurs améliorations en passant par l'uniformité puis l'invariance par rapport à la rotation, afin de combler ses limites.




Figure 35 : Exemple de voisinage LBP caractérisé par P : nombre de voisins et R : le rayon (ou distance)

5. LBP (basique) :

C'est le descripteur le plus simple dans lequel on se contente d'effectuer le seuillage. Mathématiquement parlant on obtient l'expression suivant :

$$LPB_{R,P} \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (10)$$

Avec : R et P sont les paramètres du LBP qui sont respectivement la distance entre le pixel central et ses voisins, et le nombre de pixels voisins.

g_p : Niveau de gris du pixel voisin p

g_c : Niveau de gris du pixel central c

$s(x)$: Fonction du seuillage définie par :

$$s(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$$

Exemple :

Etat de l'art




Figure 36 : Calcul du motif binaire local d'un pixel central avec 8 voisins adjacents ($P=8$ et $R=1$)

En partant de la valeur en haut à gauche on obtient $(11001010)_2 = 202$ c'est la nouvelle valeur du pixel central.

Le même calcul est effectué pour tous les pixels de l'image.

6. **LBP^u (avec motifs uniforme) :**

Au cours du travail effectué par *Ojala et al.2002* [38] Les études sur les images naturelles et texturées ont montré que la plupart des motifs calculés par LBP sont des motifs dits uniformes. Pour $P = 8$ et $R = 1$, 90% des patterns calculés sont uniformes pour $P = 16$ et $R = 2$ on trouve 70%.

Cette méthode hérite le même calcul du descripteur ordinaire sauf qu'ici on a ajouté une nouvelle contrainte pour distinguer entre les motifs uniforme et non uniforme.

Un motif est considéré uniforme s'il existe au plus deux transitions dans sa valeur binaire. Par exemple 00010000 est uniforme car il comprend exactement deux transition, la première est au niveau du 4^{ème} bit (transition de 0 à 1) la 2^{ème} est au niveau du 5^{ème} bit (transition de 1 à 0). Par contre 0101000 n'est pas uniforme il comprend quatre transition.

Etat de l'art

Cette méthode présente un grand privilège au niveau du gain de performance de calcul, puisque l'histogramme est formé principalement par les motifs uniformes. Quant aux motifs non uniformes ils sont tous regroupés dans une seule catégorie de l'histogramme. Donc pour P voisins nous avons P (P-1) + 3 valeurs de l'histogramme. Cela permet de réduire la dimension de 256 à 59 catégories.

7. **LBP^{ri} (avec invariance par rotation) :**

Le traitement de l'invariance par rapport à la rotation est très important pour se rapprocher du monde réel. Pour y parvenir un nouveau descripteur LBP a été proposé dans le même article traitant l'uniformité [38], en se basant sur le calcul de la rotation de l'opérateur LBPROT [39].

Cette méthode se base sur le fait que si on effectue une rotation de l'image, les pixels voisins changent d'emplacements et par conséquent la valeur binaire diffère. Donc pour remédier à ce genre de problème, ils ont calculé les valeurs binaires de toutes les rotations possibles et ils ont choisi la valeur minimale. De cette manière quel que soit le degré de rotation, on tombe toujours sur la même valeur minimale. Donc le nouvel opérateur **LBP^{ri}** est exprimé ainsi :

$$LBP_{P,R}^{ri} = \min_i (ROR(LBP_{R,P}, i)) \quad (11)$$

Avec $i = 0, 1, 2, \dots, P-1$ qui représente le décalage des voisins vers la droite, effectué par la fonction **ROR** exprimé ainsi dans [40] par :

$$ROR(x, i) = \begin{cases} \sum_{k=i}^{P-1} 2^{k-i} a_k + \sum_{k=0}^{i-1} 2^{P-i+k} a_k & i > 0 \\ x & i = 0 \\ ROR(x, P + i) & i < 0 \end{cases}$$

Avec :

$$x = \sum_{k=0}^{P-1} 2^k a_k \text{ avec } a_k \in \{0, 1\}$$

Dans ce cas on effectue des rotations avec 45° de pas dans le cas de 8 voisins.

Cette méthode a aussi pour avantage la réduction de la dimension de l'histogramme puisque pour 8 voisins nous n'obtenant que 36 valeurs possible au lieu de 256.

8. **LBP^{riu2} (avec invariance par rotation et uniformité) :**

Malheureusement le **LBP^{ri}** n'est performant que lorsqu'il s'agit d'une rotation à 45°, alors que dans le monde réel cette rotation est rarement trouvée. Pour combler ce point faible les chercheurs ont proposé dans [40] d'ajouter le critère d'uniformité sur les motifs.

Si le motif a une valeur d'uniformité $U \leq 2$ alors il est uniforme et l'uniformité est calculée ainsi :

$$U(x) = \sum_{p=0}^{p-1} F_b(x \oplus ROR(x, 1), p)$$

Avec

$$F_b(x, i) = ROR(x, i). (2^b - 1)$$

Et les motifs sont calculés ainsi :

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) 2^p & \text{si } U \leq 2 \\ P + 1 & \text{sinon} \end{cases} \quad (12)$$

II.5. Conclusion

Après avoir découvert les différentes méthodes destinées à la classification à base de texture, il faut maintenant choisir la méthode la plus adaptée pour notre problème.

L'amélioration des descripteurs a permis le traitement du problème des invariances. En effet l'utilisation des ondelettes chef de Haar [32] a permis d'obtenir l'invariance par rotation. Pour le cas l'autocorrélation de Gabor [33], ils ont obtenu l'invariance par rotation et par échelle. Par contre les autres méthodes *MRLBP_{u2}* [31] et *LPBGLCM* [41] se sont plutôt concentré sur la robustesse de l'analyse et la réduction du temps d'exécution.

Pour notre cas afin d'obtenir une bonne classification, il faut prendre en compte l'invariance et l'efficacité de l'analyse de la structure du polype, sans oublier le temps d'exécution.

Donc nous avons choisi la méthode de l'autocorrélation car elle est indépendante du descripteur utilisé (contrairement au *LBP^{ri}* par exemple), et par conséquent, elle peut être appliquée à un autre descripteur que Gabor.

Dans le chapitre qui suit, la première partie sera consacrée à une présentation détaillée de l'algorithme utilisé dans l'article choisi de *Riaz et al., 2012* [33]. Puis la deuxième partie traitera la modification que nous avons apportée à la méthode de base.

Présentation des méthodes

III.1. Introduction

La fonction d'autocorrélation a amélioré énormément la performance du descripteur de gabor. Ce qui nous a incités à l'appliquer dans notre problème en utilisant un autre descripteur de texture plus performant, et voir si nous pouvons obtenir de meilleurs résultats pour la classification des polypes.

Dans cette partie, nous allons connaître plus de détails sur la méthode de base, et la façon dont on a exploité l'autocorrélation, grâce à plusieurs observations sur les caractéristiques de l'image. Ensuite nous allons découvrir le nouveau descripteur que nous avons mis en place afin de tester sa robustesse avec l'autocorrélation pour atteindre l'invariance.

III.2. Présentation de la méthode de base

III.2.1. Problème posé

Dans cet article, les chercheurs ont traité le problème de classification des tissus gastro-entérologiques en se basant sur deux types d'image chromoendoscopiques (NBI et CH). Cette classification est basée sur les pit patterns CH de *Dinis Ribeiro* [42] (**Figure 37**) et ceux des NBI de *R. Singh* [43] (**Figure 38**):




Figure 37 : pit patterns CH de Dinis Ribeiro. Groupe I : Normal, Groupe II : Précancéreux, Groupe III : cancéreux




Figure 38 : pit pattern de R.Singh : A : tissu normal. B, C Précancéreux. D : Cancéreux

III.2.2. Invariance du filtre de Gabor par autocorrélation (AGF)

Soit l'image $I(x, y)$ filtrée avec un filtre de Gabor $g(x, y, f, \theta)$ avec :

x, y : Les coordonnées du pixel.

f, θ : Fréquence et orientation du filtre

9. Première propriété (Rotation) :

Si :

$r_I(x, y, f, \theta) = I(x, y) ** g(x, y, f, \theta)$, est la réponse de l'image I par convolution avec le filtre g .

Alors :

$r_{I'}(x, y, f, \theta) = r_I(x, y, f, \theta - \alpha)$, est la réponse de l'image I' étant une version orienté de I d'un angle α .

10. Deuxième propriété (L'échelle) :

Soit $I^c(x, y) = I(cx, cy)$ une image redimensionnée avec un facteur c

Alors :

$r_{I^c}(x, y, f, \theta) = \frac{1}{c^2} r_I\left(x, y, \frac{f}{c}, \theta\right)$, est la réponse de l'image I^c

11. Troisième propriété (La luminosité) :

Soit $I^{lu}(x, y) = lu * I(x, y)$ une image éclairer avec un facteur lu

Alors :

$r_{I^{lu}}(x, y, f, \theta) = lu * r_I(x, y, f, \theta)$

D'après ces propriétés, on remarque que les réponses impulsionnelles d'une image subissant un changement de rotation, d'échelle, ou de luminosité peuvent être déduites par celles de l'image originale (sans changement).

Présentation des méthodes

Pour bien exploiter ces propriétés, les chercheurs ont changé la représentation des filtres de Gabor par celle proposé par *Kamarainen et al* [44], qui consiste à assimiler à chaque pixel, une matrice contenant ses réponses dans tous les filtres. Cette représentation est appelée **espace simple des caractéristiques de Gabor (SGFS)**.

Chaque pixel possède une matrice représenté ainsi :

$$R_i(m, n) = \begin{bmatrix} r_i(x_i, y_i; f_0, \theta_0) & r_i(x_i, y_i, f_1, \theta_0) & \dots & r_i(x_i, y_i, f_{S-1}, \theta_0) \\ r_i(x_i, y_i; f_0, \theta_1) & r_i(x_i, y_i, f_1, \theta_1) & \dots & r_i(x_i, y_i, f_{S-1}, \theta_1) \\ \vdots & \vdots & \ddots & \vdots \\ r_i(x_i, y_i; f_0, \theta_{K-1}) & r_i(x_i, y_i, f_1, \theta_{K-1}) & \dots & r_i(x_i, y_i, f_{S-1}, \theta_{K-1}) \end{bmatrix}$$

Avec :

$m = 0, 1, 2 \dots, S - 1$: Indices des échelles.

$n = 0, 1, 2 \dots, K - 1$: Indices des orientations.

$r_i(x_i, y_i, f_m, \theta_n)$: Réponse du filtre de Gabor ayant la fréquence f_m et l'orientation θ_n au pixel (x_i, y_i)

De cette manière la matrice d'un pixel de l'image orientée avec un angle α et redimensionnée avec un facteur c , est déduite facilement en décalant la matrice :

$$R'_i(m, n) = R_i(m - w_c, n - w_\alpha)$$

Exemple :




Figure 39 : A) Gauche : Image Initial, Droite : Matrice d'un pixel B) Gauche : image orienté, Droite : décalage des lignes. C) Gauche : image redimensionné, Droite : décalage des colonnes.

Présentation des méthodes

Donc afin de produire l'invariance par rotation et par redimensionnement, il faudra une nouvelle matrice insensible au décalage des lignes et des colonnes. L'utilisation de l'autocorrélation est très efficace pour ce genre de problème. L'autocorrélation est la mesure de la corrélation de la matrice ou de la fonction elle-même.

La matrice d'autocorrélation de $R_i(m, n)$ est composée d'éléments suivant :

$$z_i(s, k) = \sum_{m=0}^{S-1} \sum_{n=0}^{K-1} R_i(m, n) * R_i(m + s, n + k)$$

Avec $s = 0, 1, 2, \dots (2S - 1)$ et $k = 0, 1, 2, \dots (2K - 1)$.

Finalement ils ont transformés la matrice en vecteur, et ils ont pris la moitié vu la symétrie de l'autocorrélation et donc :

$$Z_i(d) = \begin{bmatrix} z_i(0,0) \\ z_i(0,1) \\ \vdots \\ z_i(1,0) \\ z_i(1,1) \\ \vdots \\ z_i(2S-1, 2K-1) \end{bmatrix}$$

$$\rightarrow \text{AGF}_i = [Z_i(1) \quad Z_i(2) \quad \dots \quad Z_i(d/2)]$$

Avec $d = (2S - 1) * (2K - 1)$

AGF_i : autocorrélation des caractéristiques de Gabor (Autocorrelation Gabor Feature)

III.2.3. Classification

Vu le grand nombre de vecteurs produits par cette méthode $N*(d/2)$ avec N le nombre de pixel de l'image et $d/2$ est la dimension des caractéristiques issues de l'autocorrélation, ils ont proposé deux approches pouvant remédier à ce genre de problème :

12. Calcul de l'homogénéité en calculant la moyenne et la covariance AHT (Autocorrelation Homogeneous Texture).
13. Utilisation de l'algorithme de *Varma et Zisserman* [45] AGF textons (Autocorrelation Gabor Features).

III.2.3.1. Texture homogène de l'autocorrélation (AHT)

Manjunath et Ma [46], ont proposé une méthode permettant de réduire la dimensionnalité des filtres de Gabor, en effectuant des calculs statistiques de premier ordre (moyenne et covariance) pour chaque magnitude de la réponse de l'image (valeur absolue de la matrice). Ainsi si on a K réponse de Gabor pour une image, son vecteur caractéristique est composé d'un couple moyenne-covariance de chaque réponse :

$$HT = [\mu_0, \sigma_0, \mu_1, \sigma_1, \mu_2, \sigma_2 \dots \mu_{k-1}, \sigma_{k-1}]$$

Le même principe est appliqué directement sur les AGF_i afin d'obtenir un vecteur *AHT* ce qui réduit le poids de données.

Calcul de la moyenne :

$$\mu_{z_q} = \frac{1}{N} \sum_{i=1}^N Z_i(q)$$

Calcul de la covariance :

$$\sigma_{z_q} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z_i(q) - \mu_{z_q})^2}$$

Finalement →

$$AHT = [\mu_{z_1}, \sigma_{z_1}, \mu_{z_2}, \sigma_{z_2}, \dots, \mu_{z_{d/2}}, \sigma_{z_{d/2}}]$$

Représente le vecteur de caractéristiques de l'image et peut être utilisé par un classifieur.

III.2.3.2. AGF textons

Une autre approche a été proposé par *Varma et Zisserman* [45], permettant de réduire la dimensionnalité des caractéristiques. Cette méthode suit deux étapes :

a. Création d'un dictionnaire de textons.

La création du dictionnaire des textons est effectuée en établissant un regroupement sur les vecteurs AGF_i en utilisant la méthode K-Means [47], et en sélectionnant par la suite les k centroid calculés.

Présentation des méthodes

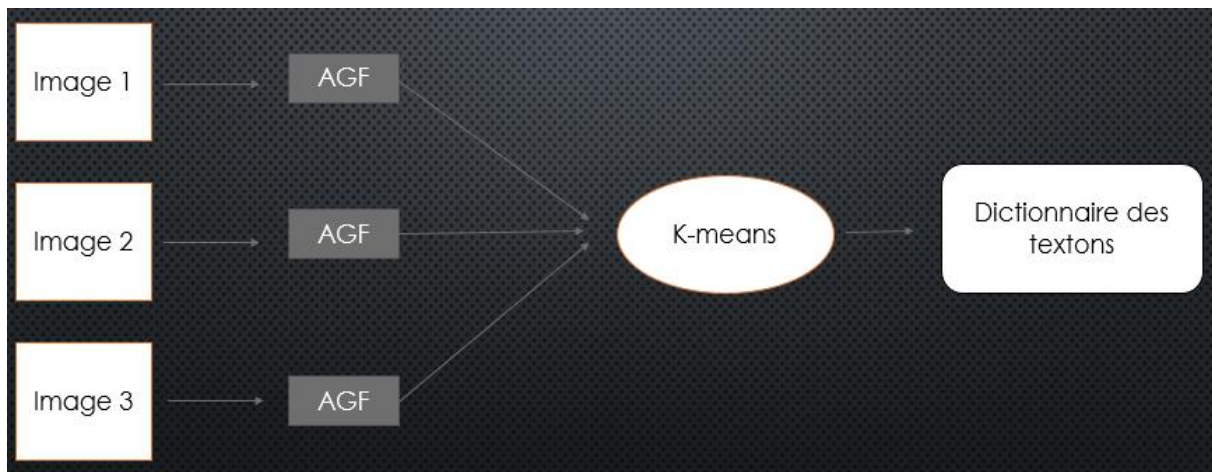


Figure 40 : Schéma montrant les étapes de la création du dictionnaire

b. Création de l'histogramme des textons.

A partir du dictionnaire des textons, nous allons construire ce qu'on appelle histogramme de textons basé sur le nombre d'occurrence des textons dans une image. L'histogramme contient t valeur avec t est le nombre des textons dans le dictionnaire.

Nous calculons la distance entre chaque vecteur AGF_i de l'image et les textons du dictionnaire, puis nous incrémentons l'effectif du texton ayant la distance la plus minimale. Cet histogramme est l'entrée d'un classifieur comme le SVM.

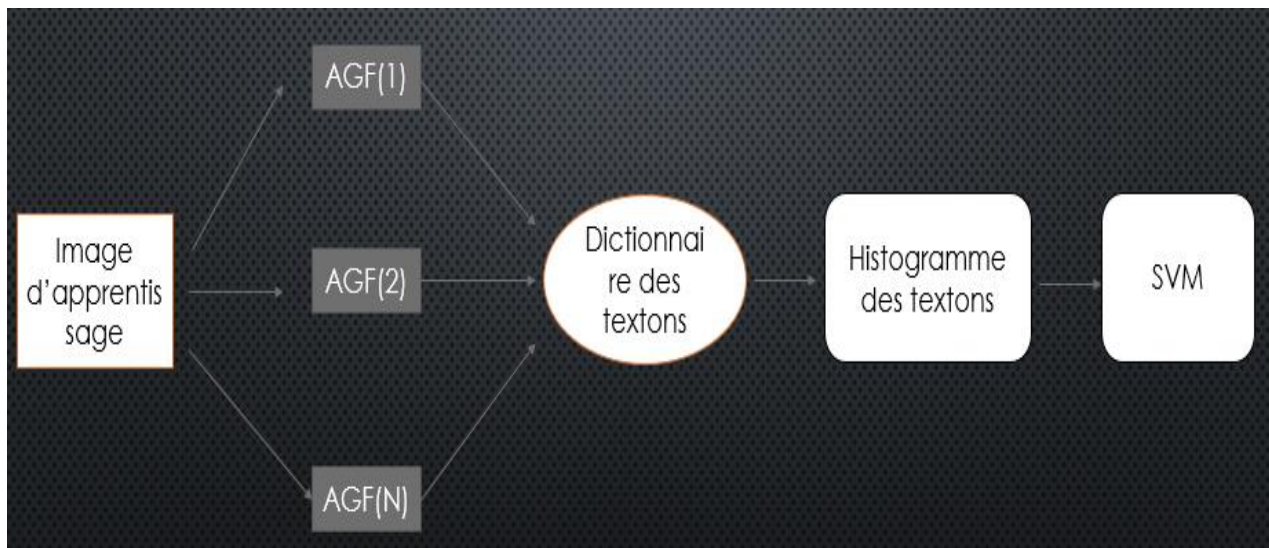


Figure 41 : Schéma montrant la création d'un histogramme de textons à partir du dictionnaire des textons

III.2.4. Schéma de l'algorithme

On commence par acquérir les images ensuite on procède au filtrage avec Gabor, puis on transforme les données du filtres sous forme d' SGFS (Simple Gabor Feature Space) dans lequel chaque pixel de l'image est représenté par une matrice ayant comme données, les niveaux de gris du pixel dans tous les filtres, ensuite on applique l'autocorrélation sur ces matrices afin de produire les AGF (Autocorrélation Gabor Feature). Finalement on peut choisir soit la méthode AHT (Autocorrélation Homogeneous Texture) ou bien la méthode AGFtextons (Autocorrélation Gabor Features).

Voici le schéma illustrant le mécanisme de la méthode :

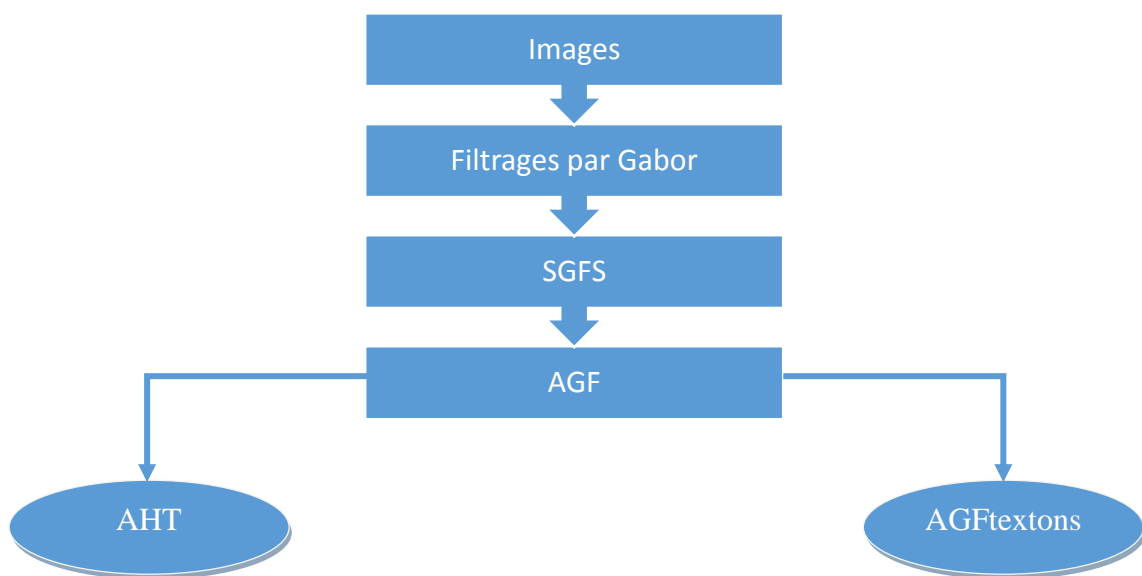


Figure 42 : Schéma global de la méthode de base

III.3. Amélioration de la méthode

Dans [29] de (Mamonov et al), 2014. Les chercheurs ont proposé une méthode ayant pour but l'extraction des polypes en se basant sur leurs formes et leurs textures. L'analyse textural représente un élément crucial dans leur approche, puisqu'elle leur a permis de distinguer entre la muqueuse normale ayant une certaine courbature, pouvant être identifiée comme polype, et le vrai polype.

Ils ont opté pour l'analyse textural de (Buades et al., 2011) [30] qui consiste à décomposer l'image en objet et sa texture. Cette approche est fondée sur des techniques simples de traitement d'image.

III.3.1. Méthode de décomposition objet - texture

La décomposition proposée par *buades et al* est basée sur le travail effectué par Yves Meyer [48], qui consiste à partitionner une image f en une somme de deux composantes : objet u et texture v . La partie u contient les différentes régions de l'image sans leurs structures (Préservation des frontières). Tandis que leurs informations texturales sont contenues dans la partie texture v .

La séparation objet texture, s'appuie sur l'application des filtrages passe-haut passe-bas suivis de la mesure de la variation totale locale LTV (Local Total Variation) permettant d'obtenir le résultat le plus optimal.

L'idée de cette méthode consiste à calculer la LTV pour l'image originale, et la comparer avec la LTV de l'image filtrée avec un filtre passe-bas. Les pixels de la partie objet (y compris les frontières) sont caractérisés par une faible variation entre l'image et sa version filtrée. Par contre, les pixels appartenant à la texture ont une forte variation.

Pour l'image objet, on affecte les valeurs de l'image originale aux pixels identifiés comme appartenant à l'objet. Le reste (pixels de texture) on leur affecte la valeur obtenu après le filtrage passe-bas.

L'image de texture est déduite facilement par la soustraction de l'image originale à celle de l'objet. $v = f - u$.

La LTV pour chaque pixel x , est définie ainsi :

$$LTV_{\sigma}(x)(f) = G_{\sigma} * |\Delta f|(x) \quad (*)$$

Avec :

G_{σ} : Le noyau de la gaussienne avec l'écart type σ

La mesure de la variation entre la $LTV_{\sigma}(x)(f)$ et $LTV_{\sigma}(x)(L_{\sigma} * f)$ est :

$$\lambda(x) = \frac{LTV_{\sigma}(x)(f) - LTV_{\sigma}(x)(L_{\sigma} * f)}{LTV_{\sigma}(x)(f)} \quad (**)$$

Si λ tend vers 0, cela se traduit par une faible variation et donc le pixel en question appartient à la partie objet. Si λ tend vers 1 alors le pixel appartient à la partie texture.

Afin de prendre en compte les valeurs λ qui présentent une ambiguïté au niveau de la décision. Ils ont défini une fonction de seuillage $w(s)$:

$$w(s) = \begin{cases} 0 & \text{si } s < \alpha_1 \\ 1 & \text{si } s > \alpha_2 \\ \frac{(s - \alpha_1)}{(\alpha_2 - \alpha_1)} & \text{si } \alpha_1 \leq s \leq \alpha_2 \end{cases} \quad (***)$$

Présentation des méthodes




Figure 43 : fonction de seuillage $w(s)$ (article [30])

Pour la fonction citée, ils ont pris $\alpha_1 = 0.25$ et $\alpha_2 = 0.5$

Finalement la valeur de chaque pixel $u(x)$ de l'objet est :

$$u(x) = w(\lambda(x))L_\sigma * f + (1 - w(\lambda(x)))f \quad (****)$$

Et l'image de la texture est :

$$v(x) = f - u(x)$$

Etapas de l'algorithme :

1) Appliquer le filtrage non-linéaire passe-bas à l'image ($L_\sigma * f$) :

Ici au lieu de passer par la transformée de Fourier, ils ont opté pour un filtrage itératif permettant d'exécuter la convolution plusieurs fois selon le schéma suivant :

$$f_{bas} \leftarrow G_\sigma * f$$

$$f_{haut} \leftarrow f - f_{bas}$$

de 1 jusqu'à n faire :

$$f_{haut} \leftarrow f_{haut} - G_\sigma * f_{haut}$$

$$f_{bas} \leftarrow f - f_{haut}$$

$L_\sigma * f$ est la dernière valeur de f_{bas}

Le paramètre n (nombre d'itérations) a été fixé à 5.

- 2) Calculer la LTV pour f et $f * L_\sigma$ avec (*).
- 3) Déduire la valeur de λ pour chaque pixel avec (**).
- 4) Calculer la fonction du seuillage $w(x)$ à chaque λ avec (***).
- 5) Calculer l'image cartoon u avec (****).
- 6) Déduire l'image texture $v = f - u$

Présentation des méthodes

Exemple :




Image Originale




Image Objet (Cartoon)




Image Texture

Figure 44 : Décomposition de l'image en texture et cartoon (objet) avec $\sigma = 10$

Comme le montre l'exemple **Figure 44** l'algorithme proposé est très efficace pour l'extraction de la texture du polype.

III.3.2. Mise en place du nouveau descripteur

Contrairement au descripteur de Gabor qui engendre une matrice descriptive de chaque pixel de l'image (orientation, échelle), le descripteur de buades dispose d'un seul paramètre qui est l'écart type de la gaussienne, ce qui nous donne un vecteur. Cette observation nous a conduits à le mettre en place au lieu du filtre de gabor afin de réduire la complexité de l'algorithme. Ainsi l'autocorrélation s'appliquera à une seule dimension.

Présentation des méthodes

Les deux approches AHT (autocorrelation homogeneous texture) et AGFTextons (autocorrelation gabor features) garderons la même structure et les même étapes vues dans **III.2.3.1** et **III.2.3.2**.

L'extraction des caractéristiques par décomposition Cartoon-Texture CTD (Cartoon-Texture Decomposition), est effectuée en appliquant plusieurs filtrages sur l'image, en variant le paramètre σ .

Donc, notre schéma de la méthode proposée est le suivant :

CTD : Cartoon Texture Decomposition.

SCTDFS : Simple CTD Feature Space.

ACTD : Autocorrelation CTD

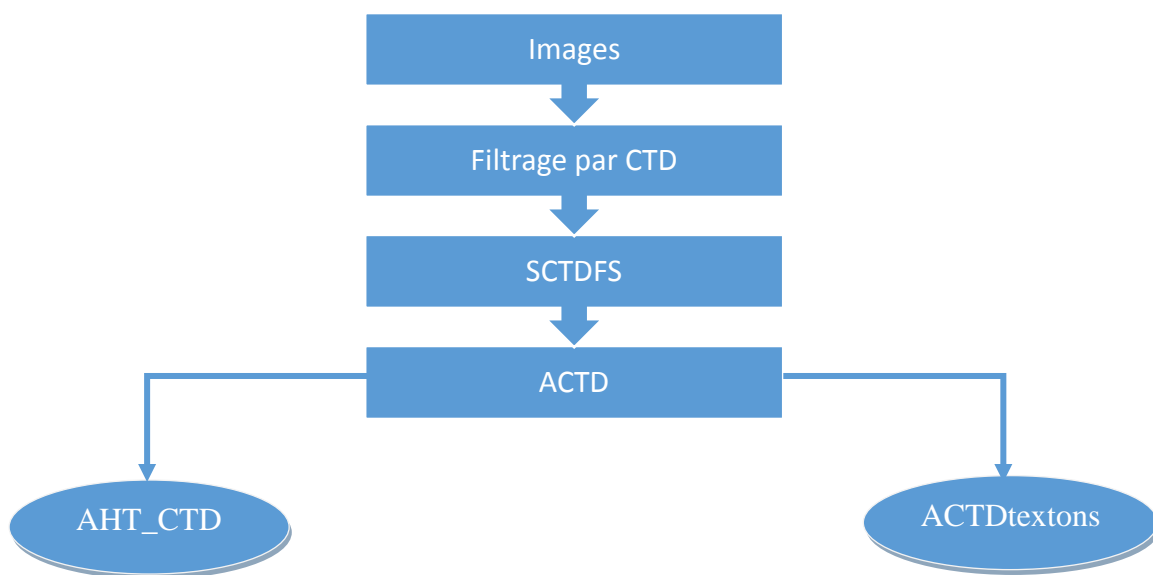


Figure 45: Schéma global de la méthode proposée

III.4. Conclusion

Dans ce chapitre, nous avons détaillé les différentes méthodes sur lesquelles nous nous sommes basés. Nous avons expliqué comment fonctionne l'autocorrélation avec le filtre de gabor. Puis nous avons proposé de mettre en place un nouveau descripteur plus souple, qui a prouvé auparavant sa robustesse au niveau de la distinction entre la muqueuse normal et celle du polype.

Finalement, dans le chapitre qui suit, nous allons découvrir les différents tests que nous avons effectués afin de valider notre nouvelle approche. Puis nous aurons à la fin une conclusion sous forme de synthèse dans laquelle nous discutons les différents résultats que nous avons obtenus.

Chapitre IV

Implémentation et résultats

IV.1. Introduction

Afin d'implémenter les différentes méthodes choisies et comparer les différents résultats obtenus, nous avons opté pour la programmation sous le langage Python [49] (version 2.7). Ce choix est dû à sa puissance de calcul par rapport à Matlab. Or, des packages sont à installer manuellement.

Les modules que nous avons installés sont :

- **Numpy** (<http://www.numpy.org/>) : permet la manipulation des matrices (création, copiage, enregistrement dans un fichier ...).
- **Scipy** (<https://www.scipy.org/>): permet la manipulation des images (lecture, enregistrement...).
- **Matplotlib** (<http://matplotlib.org>) : permet la visualisation graphique des résultats.
- **Scikit-image** (<http://scikit-image.org/>) : module contenant des techniques de traitement d'images (détection des contours, morphologie, filtrage...).
- **Scikit-learn** (<http://scikit-learn.org/stable>) : module contenant les méthodes de classification et de clustering (ANN, SVM, KMeans).

Pour les mesures des performances, nous avons opté pour l'utilisation du Framework **Orange** (<http://orange.biolab.si/>)

La base de données des polypes cancéreux et non cancéreux ont été récupérés depuis le Centre Hospitalier Universitaire de Fès. Nous avons pris 114 images dont 57 pour les polypes cancéreux et 57 pour les polypes non cancéreux.

Les différents tests ont été réalisés avec un processeur i5 2.4GHZ, et 8Go au niveau de la RAM.

Par mesure d'optimisation du calcul nous avons pris le canal rouge de chaque image au lieu de prendre l'image en format RGB, car le rouge contient la quasi-totalité d'informations.

14. Exemple :




Figure 46 : A gauche polype en mode RGB, A droite l'information du rouge de l'image




Figure 47 : A gauche cancer en mode RGB, A droite l'information du rouge de l'image

IV.2. Classification

Afin d'évaluer la performance au niveau de l'apprentissage et le test de nos données, nous avons utilisé des mesures se basant sur trois informations à calculer pour chaque classe. Il s'agit de :

15. Les **vrais positifs** (vp) :

Les vrais positifs d'une classe sont les entrées qui lui ont bien été affectées.

16. Les **faux positifs** (fp) :

Les faux positifs d'une classe sont les entrées qui lui ont été affectées mais qui n'appartiennent guère à cette classe.

17. Les **faux négatifs** (fn) :

Les faux négatifs d'une classe sont les entrées lui appartenant, mais qui ont été mal classifiées (affectées à une autre classe).

Maintenant nous allons découvrir les mesures sur lesquelles nous nous sommes basées.

a. La Précision :

La précision d'une classe, a pour but de déterminer jusqu'à quel point un classifieur est capable de ne pas affecter un modèle qui ne correspond pas à cette classe.

Dans notre cas, un classifieur ayant une bonne précision, est celui qui ne reconnaît pas le polype en tant que cancer et vis-versa. Le plus important des deux cas est le fait de ne pas reconnaître un cancer en tant que polype. Dans le cas contraire on ne peut faire confiance à un tel classifieur, sinon le patient court un grand danger.

Donc = La précision est mesurée ainsi :

$$Précision_c = \frac{vp}{vp + fp}$$

Implémentation et résultats

D'après l'expression on constate que plus la valeur vp augmente, plus la précision s'approche de 1 qui correspond à la meilleure performance. La somme $vp + fp$ correspond à tous les modèles qui ont été affectés à la classe c . Donc plus les faux positifs augmentent, plus nous obtenons une mauvaise précision.

b. Le Rappel :

Le rappel nous donne une autre information dans une classe. C'est l'aptitude d'un classifieur, à lui affecter le maximum d'exemple lui appartenant. C'est-à-dire, dans notre problème, un classifieur ayant un bon rappel, est celui qui est capable de reconnaître le maximum des polypes et le maximum des cancers.

Le rappel, est exprimé ainsi.

$$Rappel_c = \frac{vp}{vp + fn}$$

Le dénominateur n'est autre que le nombre total d'instances appartenant à la classe puisque les vp appartiennent à la classe, les fn également mais, elles ont été mal classifiées.

c. La Fmesure :

La Fmesure tend à déduire la robustesse du classifieur, en se basant sur le rappel et la précision, en calculant leur moyenne harmonique.

$$Fmesure_c = 2 \left(\frac{Rappel_c * Précision_c}{Rappel_c + Précision_c} \right)$$

d. L'exactitude :

L'exactitude nous permet d'avoir une vision globale sur les performances des classifieurs, en calculant tout simplement le pourcentage des bonnes classifications :

$$Exactitude = \frac{\text{Nombre des prédictions correctes}}{\text{Nombre total des données}}$$

IV.2.1. Techniques d'évaluations

Nous avons pris deux techniques d'évaluation de performance, sur lesquelles nous nous sommes basées pour discuter les résultats :

IV.2.1.1. Evaluation par validation croisée (cross-validation)

Cette technique permet d'évaluer toutes les données en changeant à chaque fois leur rôle (données d'apprentissage ou données de tests).

Pour cela, on procède à un partitionnement des données en k blocs, et on prend à chaque fois un bloc pour le test et les autres sont utilisés pour l'apprentissage.

Cette évaluation nous permet d'obtenir les résultats indépendamment du choix des données d'apprentissages et de tests.

IV.2.1.2. Evaluation par échantillonnage aléatoires (random simpling)

Cette technique consiste à sélectionner aléatoirement un pourcentage de données réservées pour l'apprentissage. Cela permet d'éliminer l'ordre dans lequel sont classées les données, qui pourra influencer sur l'apprentissage.

En changeant à chaque le pourcentage de données d'apprentissage, on peut détecter le phénomène de surapprentissage.

Maintenant que nous connaissons les différentes techniques relatives à la mesure de performance, nous passons à leur application sur notre travail.

IV.2.2. Méthode de base

La méthode de base comprend deux approches se basant sur les vecteurs AGF :

18. AGF_textons.
19. AGF_AHT.

Pour l'évaluation de la première méthode nous allons procéder comme suit :

20. Le nombre d'échelles et d'orientations a été fixé respectivement à 6 et 8 en se basant sur l'article.
21. Le nombre de textons par image, permettant de créer le dictionnaire est varié de 2 à 6 avec un pas de 2, afin d'analyser l'impact du nombre de textons sur la classification.

Implémentation et résultats

22. Pour chaque nombre de textons, les deux méthodes d'évaluation sont appliquées et les différentes mesures sont enregistrées.

23. Pour la validation croisée, nous avons partitionné la base de données en 38 images (38-cross fold) ce qui nous donne trois partitions.

24. Pour la validation par échantillonnage aléatoire on incrémente la base d'apprentissage par 20% (20% 40% 60% 80%).

25. D'après les résultats préliminaires obtenus, nous avons constaté une meilleure performance du classifieur **SVM linéaire**, donc nous l'avons sélectionné pour obtenir les résultats.

IV.2.2.1. Descripteur AGF_textons

Après la création des modèles, nous avons évalué les performances citées au préalable avec le Framework Orange.

Tout d'abord la **Figure 48**, illustre le temps d'exécution de chaque image, en fonction du nombre de textons choisi. On remarque que les deux variables sont proportionnelles, puisque plus le nombre de textons augmente, plus la complexité du calcul augmente aussi. Cela n'est pas dû au vecteur AGF, puisque le nombre de pixels des images demeure le même, et les paramètres du filtre de gabor sont fixés. Or l'augmentation du nombre de texton engendre l'élévation de la dimension de l'histogramme des textons, qui représente le vecteur caractéristique des images. Ce qui fait que le temps de calcul des distances entre les AGF de l'image et les AGF du dictionnaire des textons, croit considérablement.




Figure 48 : Evolution du temps de calcul par image, en fonction du nombre de textons choisi

Implémentation et résultats

D'après les résultats obtenus et présentés dans la **Figure 49** et la **Figure 50**, on remarque clairement que la méthode utilisant 4 textons dépasse largement celles qui utilisent 2 ou 6 textons.

On remarque aussi que le rappel sur la classe des cancers est assez élevé, ce qui veut dire que le classifieur arrive à reconnaître la quasi-totalité des cancers, ce qui diminue le risque de ne pas reconnaître en tant que polype. D'un autre côté la précision sur la classe des polypes est très bonne donc on en déduit que le classifieur n'affecte pas de cancer à la classe des polypes dans la majorité des cas (nombre de faux positifs faible).




Figure 49 : Résultats obtenus par validation croisée sur la classe des polypes




Figure 50 : Résultat obtenu par validation croisée sur la classe des cancers

Implémentation et résultats

Pour la deuxième expérience (sélection aléatoire) on remarque que pour chaque pourcentage d'apprentissage, l'utilisation de 4 textons donne un meilleur résultat. La valeur marquée en vert représente le meilleur résultat dans un pourcentage d'apprentissage. Et On remarque aussi le phénomène de surapprentissage pour 4 textons puisque de 40% à 60% on passe de $EC = 0.917$ à $EC = 0.909$ le même cas pour la Fm , puis une augmentation de précision et une dégradation du rappel. D'après cette analyse de choix le plus convenable serait 40%.

NB : EC : Exactitude

Fm : Fmesure

%apprentissage	Nombre de textons	EC	Fm	Précision	Rappel
20%	2	0.803	0.811	0.767	0.860
	4	0.876	0.877	0.856	0.898
	6	0.876	0.875	0.864	0.887
40%	2	0.857	0.855	0.874	0.836
	4	0.917	0.917	0.927	0.908
	6	0.887	0.888	0.886	0.891
60%	2	0.872	0.870	0.921	0.825
	4	0.909	0.909	0.946	0.875
	6	0.885	0.889	0.895	0.883
80%	2	0.887	0.889	0.920	0.860
	4	0.913	0.916	0.932	0.901
	6	0.904	0.908	0.916	0.901

Tableau 1 : résultat obtenus par la technique d'échantillonnage aléatoire

Les résultats obtenus en utilisant l'approche AGFtextons sont très intéressantes. Ils nous confirment le bon choix du nombre de textons utilisé dans l'article de base qui est 4.

IV.2.2.2. Descripteur AGF_AHT

Nous allons analyser la 2^{ème} approche se basant sur les AGF qui est une approche très simple par rapport à la précédente, puisque aucun paramètre n'est ajouté. Il suffit juste de mesurer la moyenne et la covariance entre les composantes des AGF de l'image. Puisque les paramètres de gabor sont fixés. Un seul résultat est obtenu pour chaque technique de mesure.

L'extraction a duré 52min pour extraire les caractéristiques des 114 images ce qui donne en moyenne à peu près 27seconde/image.

Le **Tableau 2**, représente toutes les mesures obtenues par validation croisée. À première vue, nous remarquons que cette méthode est moins fiable par rapport à la méthode AGFtextons utilisant le nombre de textons le plus inférieur qui est 2. Par contre l'extraction des caractéristiques par cette dernière a duré 92min ce qui fait près de 48seconde/image.

Implémentation et résultats

Classe	EC	Fm	Précision	Rappel
Cancer	0.746	0.748	0.741	0.754
Polype	0.746	0.743	0.750	0.737
Moyenne	0.746	0.745	0.745	0.745

Tableau 2 : Evaluation de la méthode AGF_AHT par validation croisée

Pour la deuxième évaluation (**Tableau 3**) nous constatons que les performances augmentent considérablement lorsqu'on utilise un nombre spécifique de données d'apprentissage. Lors de l'utilisation de la quasi-totalité des données (80%) comme apprentissage on obtient un meilleur résultat. On peut également considérer que le résultat obtenu avec seulement 20% d'apprentissage est très intéressant vu le nombre de données sur lesquelles se base le classifieur. Par contre les résultats intermédiaires dégradent les performances du classifieur.

%d'apprentissage	Classe	EC	Fm	Précision	Rappel
20%	Cancer	0.840	0.835	0.882	0.793
	Polype	0.840	0.845	0.805	0.889
	Moyenne	0.840	0.840	0.843	0.841
40%	Cancer	0.830	0.828	0.834	0.822
	Polype	0.830	0.833	0.827	0.839
	Moyenne	0.830	0.830	0.830	0.830
60%	Cancer	0.828	0.831	0.785	0.822
	Polype	0.828	0.826	0.878	0.779
	Moyenne	0.828	0.825	0.831	0.801
80%	Cancer	0.857	0.847	0.858	0.835
	Polype	0.857	0.865	0.855	0.876
	Moyenne	0.857	0.856	0.856	0.855

Tableau 3 : Evaluation de la méthode AGF_AHT par échantillonnage aléatoire

D'après les résultats obtenus des deux approches, on peut déduire que la méthode AGFTextons est plus précise par rapport à l'AHT_AGF. Par contre cette dernière peut être améliorée en optimisant les données pour avoir une bonne mesure des moyennes et des covariances. On peut utiliser par exemple la technique PCA (principal Components Analysis).

IV.2.3. Méthode proposée

Maintenant nous allons analyser les résultats obtenus avec la méthode que nous avons mise en place, et qui se base sur la même structure de la précédente.

Les mêmes techniques de mesure ont été appliquées :

Pour la technique se basant sur les textons : ACTDtextons (Autocorrelation Cartoon Texture Décompositon). Nous avons fait varier le nombre de textons de 2 à 6 avec un pas de 2. Pour chaque nombre de textons, on varie le paramètre σ de l'algorithme de buades de 2 à 10 en changeant le pas de 1 à 4.

Pour la méthode ACTD_AHT, le seul paramètre à varier est le σ de 1 à 10 avec les pas allant de 1 à 4.

IV.2.3.1. Descripteur ACTDtextons

Tout d'abord nous allons analyser la variation du temps de calcul par rapport au nombre de textons et au pas du sigma. La **Figure 51** représente la variation du temps (min/image) en fonction du nombre de texton (nt) et du pas du sigma choisi. Comme dans la méthode précédente nous remarquons l'élévation de la complexité du calcul lorsqu'on augmente le nombre de textons. Par contre lorsqu'on augmente le pas du sigma le temps de calcul diminue. Cela est tout à fait normal, car pour $ps = 1$ (pas du sigma), 10 images textures sont calculées par l'algorithme de décomposition. Alors que si nous incrémentons le pas à 2 nous obtenant que 5 images texturent, et dans ce cas le traitement est assez rapide.




Figure 51 : Evaluation du temps par rapport aux pas du sigma (ps), et au nombre de textons par image (nt)

Implémentation et résultats

Afin de bien structurer notre analyse de cette méthode, nous allons traiter chaque nombre de textons et discuter le paramètre sigma qui lui convient.

D'après la **Figure 52**, qui représente l'histogramme où le nombre de textons est 2, on remarque que pour $ps = 3$, nous obtenons de meilleures performances pour les trois métriques (rappel = 0.807, précision = 0.767, fmesure = 0.767), ce qui est très intéressant puisqu'on réduit le temps de calcul par rapport au $ps = 1$ et $ps = 2$. Pour $ps = 4$ on constate une chute dans les mesures ce qui s'explique par le manque d'informations dans les modèles obtenus.

La **Figure 53**, représente le résultat pour 4 textons utilisées. On remarque que les valeurs des métriques sont assez équilibrées pour $ps = 1, 2, 3$. Le meilleur résultat est obtenu lorsqu'on utilise le $ps = 1$. Par contre l'utilisation du $ps = 4$ augmente fortement le rappel mais la précision est assez faible par rapport aux autres pas.

La **Figure 54** représente le résultat obtenu par 6 textons, dans lequel nous obtenons le meilleur résultat pour $ps = 3$.

De point de vue robustesse de classification, on constate que les paramètres ($nt=4, ps=1$) et ($nt=6, ps=3$) donne de meilleurs résultats. Or de point de vue temps d'exécution, l'extraction des caractéristiques pour les premiers paramètres dure 1.01min/image, alors que pour les autres paramètres le temps d'exécution dure 0.95min/image. Donc ($nt=6, ps=3$) donnent les meilleures performances pour l'évaluation par validation croisée.




Figure 52 : évaluation par validation croisée $nt = 2$

Implémentation et résultats




Figure 53 : évaluation par validation croisée $nt = 4$




Figure 54 : évaluation par validation croisée $nt = 6$

Implémentation et résultats

Pour la deuxième technique de mesure, nous avons réparti les informations sur 3 tableaux (**Tableau 4**, **Tableau 5**, **Tableau 6**) chacun contient les résultats d'un nombre de textons fixé.

Pour $nt = 2$, le meilleur résultat est obtenu lorsqu'on utilise $ps = 2$ avec 80% de données d'apprentissage. Pour ($nt=4$, $ps=2$) avec 40% d'apprentissage on atteint une bonne performance. Finalement les paramètres ($nt=6$, $ps=3$) présentent un résultat meilleur, si nous considérons le pourcentage de données d'apprentissage qui est 40% par rapport à l'utilisation de ($nt=2$, $ps=2$).

%d'apprentissage	Pas du sigma	EC	Fm	Précision	Rappel
20%	1	0.760	0.749	0.767	0.732
	2	0.807	0.803	0.801	0.805
	3	0.791	0.805	0.792	0.818
	4	0.735	0.732	0.721	0.744
40%	1	0.777	0.776	0.785	0.767
	2	0.813	0.813	0.819	0.807
	3	0.768	0.777	0.754	0.802
	4	0.786	0.782	0.803	0.761
60%	1	0.789	0.791	0.818	0.767
	2	0.833	0.834	0.862	0.807
	3	0.756	0.761	0.771	0.751
	4	0.714	0.706	0.744	0.671
80%	1	0.787	0.797	0.800	0.793
	2	0.848	0.852	0.871	0.835
	3	0.791	0.805	0.792	0.818
	4	0.648	0.630	0.704	0.570

Tableau 4 : Evaluation par échantillonnage aléatoire pour $nt = 2$

Implémentation et résultats

%d'apprentissage	Pas du sigma	EC	Fm	Précision	Rappel
20%	1	0.791	0.785	0.794	0.776
	2	0.801	0.799	0.785	0.813
	3	0.738	0.740	0.713	0.768
	4	0.749	0.745	0.739	0.751
40%	1	0.775	0.781	0.769	0.793
	2	0.824	0.825	0.827	0.823
	3	0.765	0.764	0.775	0.753
	4	0.806	0.804	0.830	0.779
60%	1	0.796	0.803	0.800	0.807
	2	0.782	0.786	0.789	0.782
	3	0.764	0.759	0.792	0.729
	4	0.802	0.801	0.835	0.770
80%	1	0.791	0.805	0.792	0.818
	2	0.787	0.790	0.821	0.760
	3	0.774	0.782	0.795	0.769
	4	0.783	0.798	0.780	0.818

Tableau 5 : Evaluation par échantillonnage aléatoire pour $nt = 4$

%d'apprentissage	Pas du sigma	EC	Fm	Précision	Rappel
20%	1	0.765	0.756	0.767	0.744
	2	0.768	0.771	0.740	0.806
	3	0.782	0.786	0.751	0.824
	4	0.744	0.737	0.737	0.737
40%	1	0.791	0.798	0.786	0.810
	2	0.802	0.808	0.796	0.819
	3	0.833	0.839	0.822	0.855
	4	0.788	0.784	0.809	0.762
60%	1	0.777	0.781	0.785	0.778
	2	0.793	0.802	0.797	0.807
	3	0.824	0.834	0.816	0.854
	4	0.795	0.804	0.792	0.816
80%	1	0.791	0.813	0.775	0.855
	2	0.805	0.823	0.794	0.855
	3	0.822	0.834	0.817	0.851
	4	0.809	0.823	0.803	0.843

Tableau 6 : Evaluation par échantillonnage aléatoire pour $nt = 6$

IV.2.3.2. Descripteur ACTD_AHT

Maintenant nous allons évaluer la performance de descripteur ACTD_AHT :

Tout d'abord voyons le temps d'exécution de chaque pas pour ce descripteur : plus le pas augmente plus le temps d'exécution diminue.




Figure 55 : Evolution du temps par rapport au choix du pas du sigma

La **Figure 56**, représente les résultats obtenus avec l'évaluation par validation croisée. Nous avons obtenu un meilleur résultat pour ps = 4 avec le résultat suivant :

Précision = 0.692

Rappel = 0.789

Fmesure = 0.738

Implémentation et résultats




Figure 56 : Evaluation par validation croisée

Pour la validation par échantillonnage aléatoire, Lorsqu'on utilise 20% d'apprentissage (Figure 57), on obtient le meilleur résultat pour $ps = 1$ avec $F_m = 0.684$. Pour 40% d'apprentissage (Figure 58) les résultats ne sont pas satisfaisants. Or pour 60% et 80% d'apprentissage (Figure 59 et Figure 60), on constate une faible amélioration de la $F_m = 0.688$ qui nous donne la meilleure performance.

Vu la performance du $ps = 4$ pour la validation croisée qui dépasse celle du $ps = 1$, et compte tenu de son résultat obtenu pour 20% d'apprentissage avec $F_m = 0.67$. En plus du temps d'exécution qui est assez réduit. Nous déduisons que le paramètre $ps = 4$ avec 20% d'apprentissage est meilleur choix pour la méthode ACTD_AHT.




Figure 57 : Evaluation par échantillonnage aléatoire sur 20%

Implémentation et résultats




Figure 58 : Evaluation par échantillonnage aléatoire sur 40%




Figure 59 : Evaluation par échantillonnage aléatoire sur 60% de donnée d'apprentissage




Figure 60 : Evaluation par échantillonnage aléatoire sur 80% de donnée d'apprentissage

IV.3. Synthèse

La **Figure 61** représente un résumé sous forme de diagramme en bâtons, dans lequel nous trouvons les mesures de performances avec les meilleurs paramètres pour chaque méthode. Nous remarquons que la méthode AGFtextons donne la meilleure classification suivie de ACTDtextons puis AGF_AHT et enfin ACTD_AHT. Donc l'algorithme de *Varma et Zisserman* est très efficace. Or de point de vue temps d'exécution, l'approche AHT est largement meilleure. On remarque que pour l'approche ACTD_AHT, nous avons obtenu un bon résultat avec moins d'informations fournies, puisque pour $ps = 4$, il n'y a que trois images texture à calculer (ce qui explique le temps d'exécution). Donc nous pouvons améliorer ce descripteur afin d'obtenir un bon résultat et un temps d'exécution raisonnable.




Figure 61: récapitulation des meilleurs résultats obtenus pour chaque descripteur

IV.4. Segmentation

Afin de classifier les polypes, nous avons procédé tout d'abord à leur extraction à partir des images endoscopique.

L'algorithme de segmentation que nous avons utilisé se base sur deux informations :

- La couleur : permettant de localiser la zone où se trouve le polype.
- L'analyse de la texture : permettant de déterminer le polype dans cette zone et de l'extraire par la suite.

L'algorithme proposé suit les étapes suivantes :

1. Déterminer les zones susceptibles de contenir le polype :

En analysant l'histogramme, nous avons déduit que l'information pertinente se trouve dans la composante rouge de l'image, du fait que le polype est une sorte d'inflammation, donc ils sont un peu rouge que la muqueuse normale. Cette observation nous a conduites à utiliser le seuillage par histogramme, qui consiste à détecter le plus grand pique rouge et pour chaque pixel on vérifie si la médiane de son voisinage est supérieure au seuil déterminé par le pique. Cette méthode a été nommée MedThresh (Median Thresholding)

2. Eliminer le bruit causé par le flash :

Il s'agit d'un seuillage simple qui remplace les fortes intensités par le noir.

Implémentation et résultats

3. Analyse de texture par buades puis une convolution non linéaire :

Le polype est aussi caractérisé par sa texture, donc nous avons opté pour l'analyse par l'algorithme de buades, afin d'extraire la texture de chaque région. Ensuite nous appliquant un convolution non linéaire [29] permettant de mieux représenter la texture de chaque région.

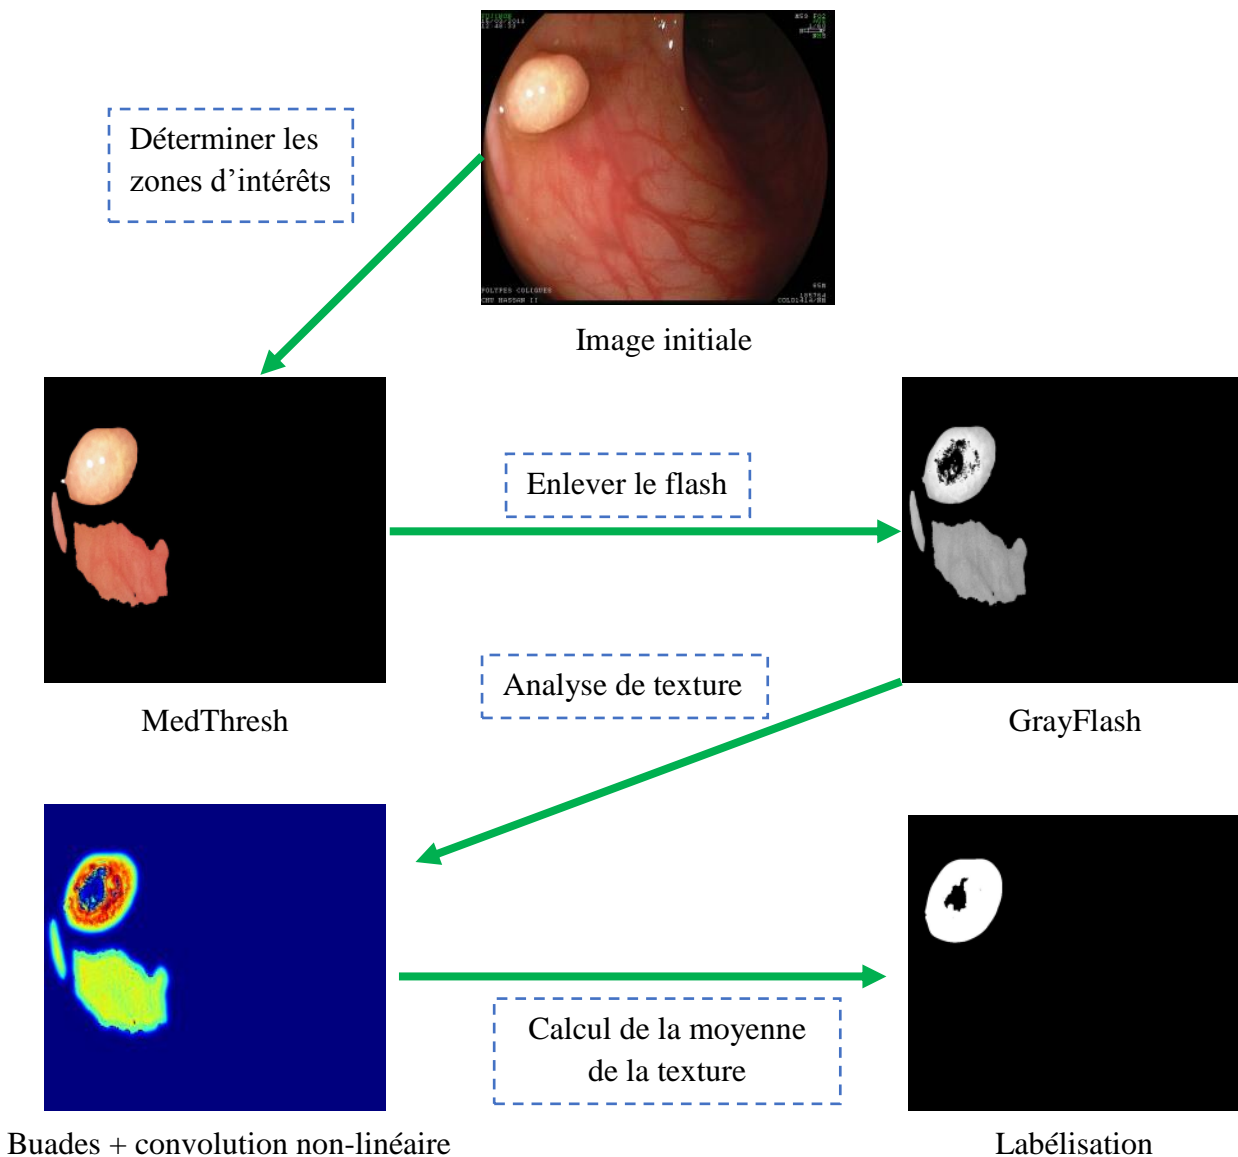
4. Déterminer la zone contenant le polype :

Premièrement nous commençons par labéliser chaque région, ensuite nous calculons la moyenne de texture de chaque zone. La zone ayant la plus grande moyenne de texture est celle qui contient probablement le polype.


5. Remplacer les pixels noirs du flash :

Dans l'étape 2, nous avons remplacé le pixel du flash par le noir. Maintenant que l'image ne contient que le polype, nous allons remplacer les noirs par la moyenne des intensités voisines.

Exemple :



Implémentation et résultats



Impainting

Le résultat de la méthode est assez satisfaisant, en fixant les paramètres de la fenêtre de la médiane et le seuil. Elle peut être automatisée en utilisant un fenêtrage adaptatif. Ensuite le noir n'est pas entièrement éliminer, il faut améliorer ce point aussi.

IV.5. Présentation de l'application

L'application a été conçue afin de montrer les différentes étapes de chaque algorithme utilisé dans notre travail. Elle comprend trois onglets :

- Onglet réservé pour la segmentation.
- Onglet réservé pour les descripteurs.
- Onglet réservé pour la classification.

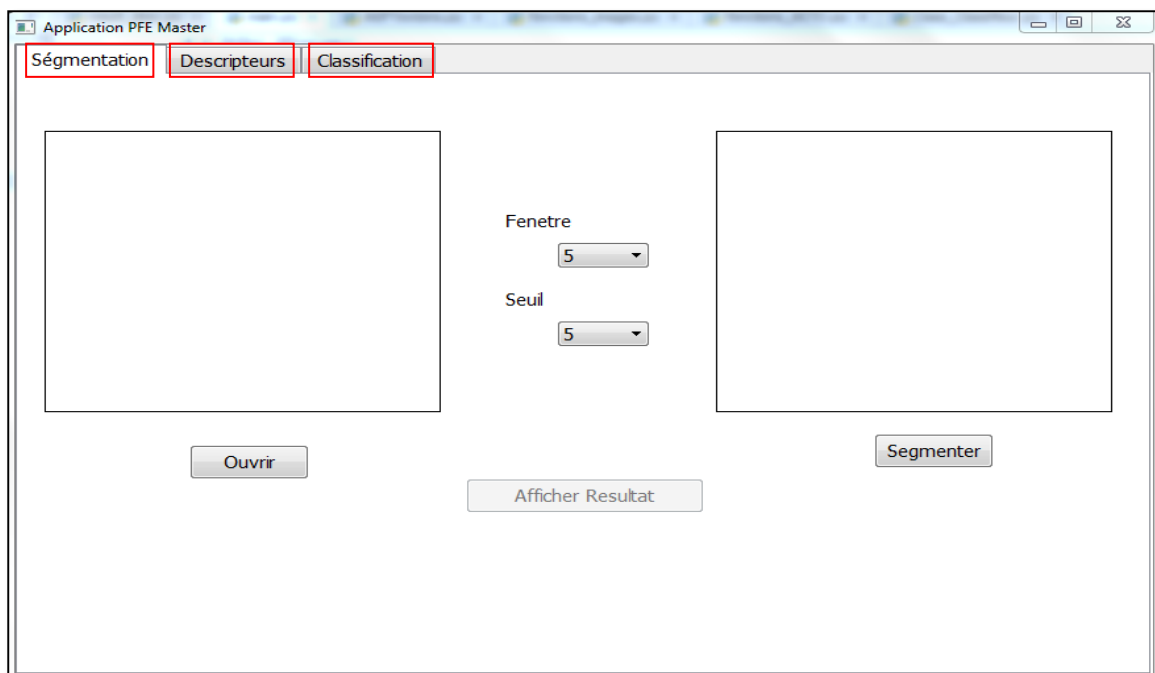


Figure 62: Présentation de l'application (elle pointe sur l'onglet de segmentation)

IV.5.1. Onglet de segmentation

La partie segmentation est très simple. Comme le montre la **Figure 63**, dans la partie gauche, on télécharge une image grâce au bouton « Ouvrir », puis l'image s'affiche dans la zone de gauche. Ensuite on procède à l'extraction du polype en appuyant sur le bouton « Segmenter ». Lorsque la segmentation est terminée, on affiche le résultat final qui est le polype tout seul.

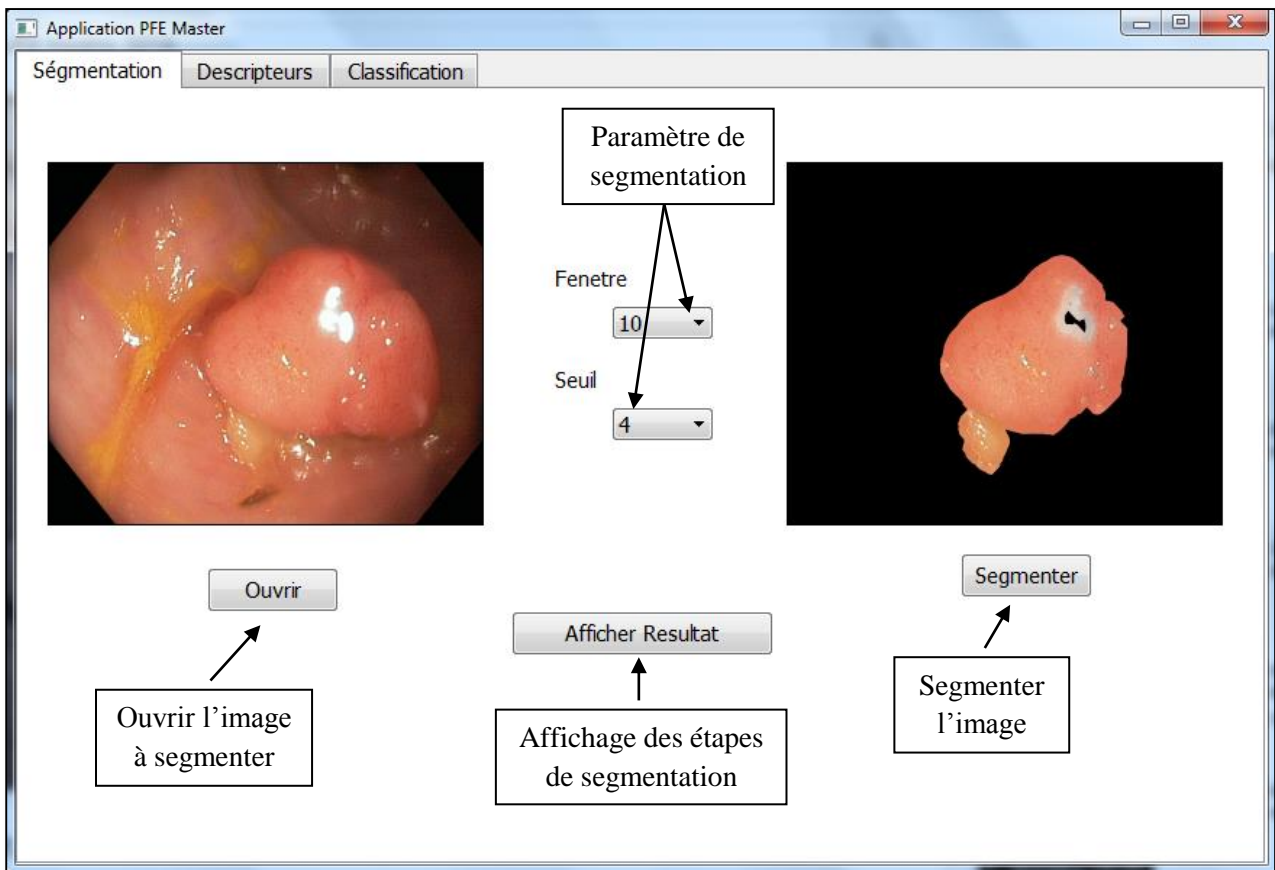


Figure 63 : présentation de l'onglet de segmentation

Afin de connaître plus de détails sur la façon dont l'image a été segmentée, nous pouvons afficher les différentes images intermédiaires avec le bouton « Afficher Résultat ». Une fenêtre s'affiche montrant les différentes étapes (**Figure 64**)

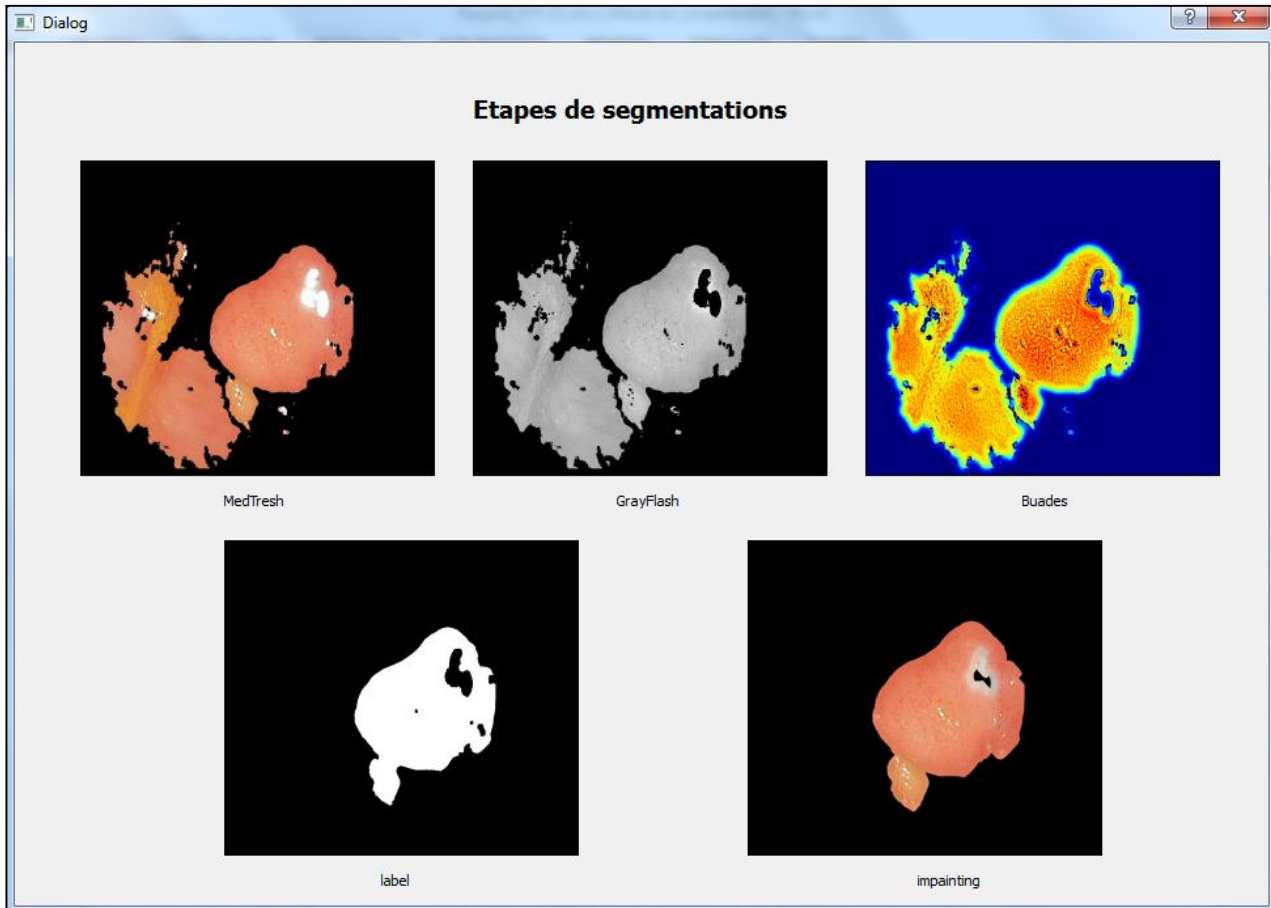


Figure 64 : Affichage des étapes de segmentation

IV.5.2. Onglet des descripteurs

Cet onglet permet de montrer les étapes d'extraction des caractéristiques d'une image entrée avec un descripteur donné.

Chaque descripteur possède ses propres paramètres. Dans la **Figure 65**, à gauche on trouve l'image dont on veut extraire les caractéristiques. La partie droite est consacrée pour la sélection du descripteur et ses paramètres (Exemple de l'AGFtextons)

Implémentation et résultats

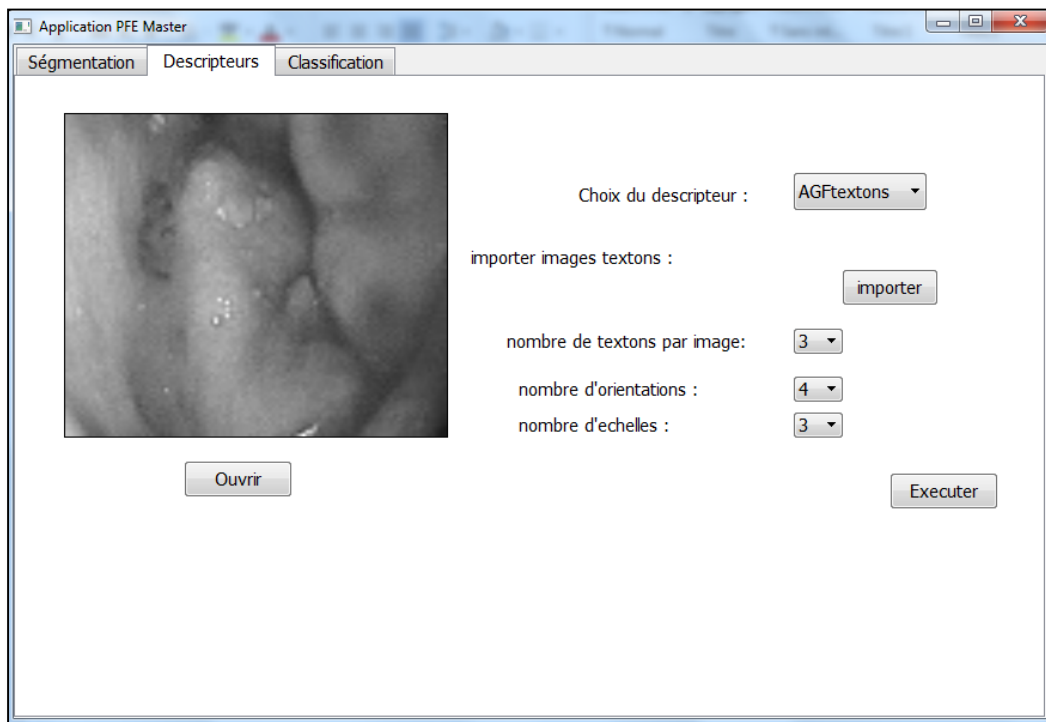


Figure 65 : Présentation de l'onglet des descripteurs

Une fois le descripteur a été paramétré, on appuie sur le bouton « Exécuter ». Ensuite une fenêtre dialogue s'affiche avec les boutons suivant et précédent, pour basculer entre les différentes étapes.

Pour les paramètres de la **Figure 65**, on trouve les résultats suivant :

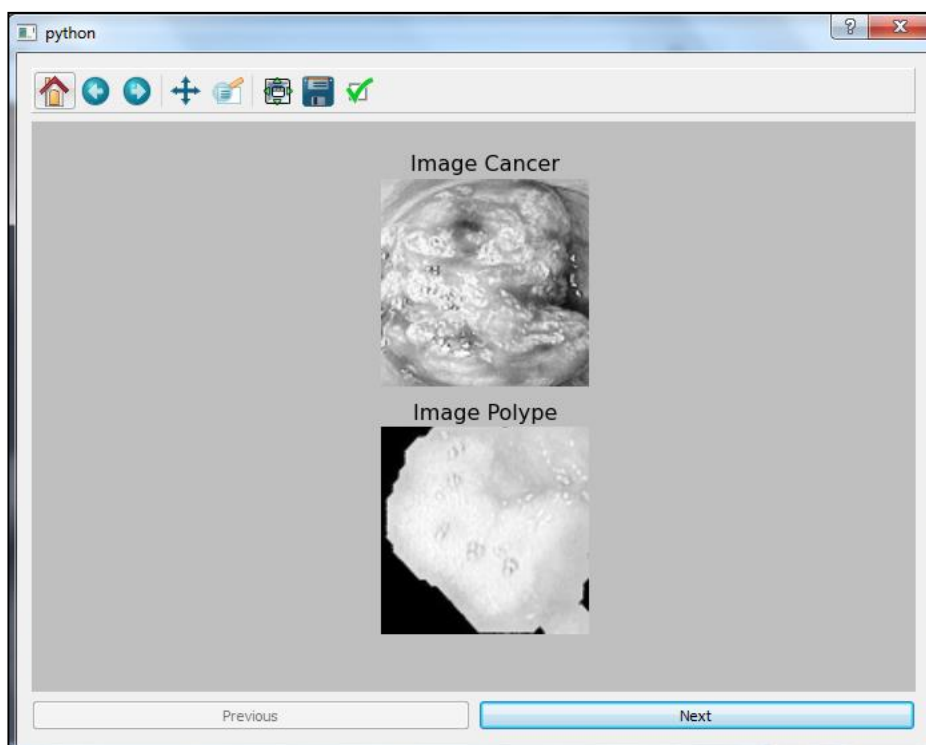


Figure 66: exemple d'images de textons utilisées

Implémentation et résultats

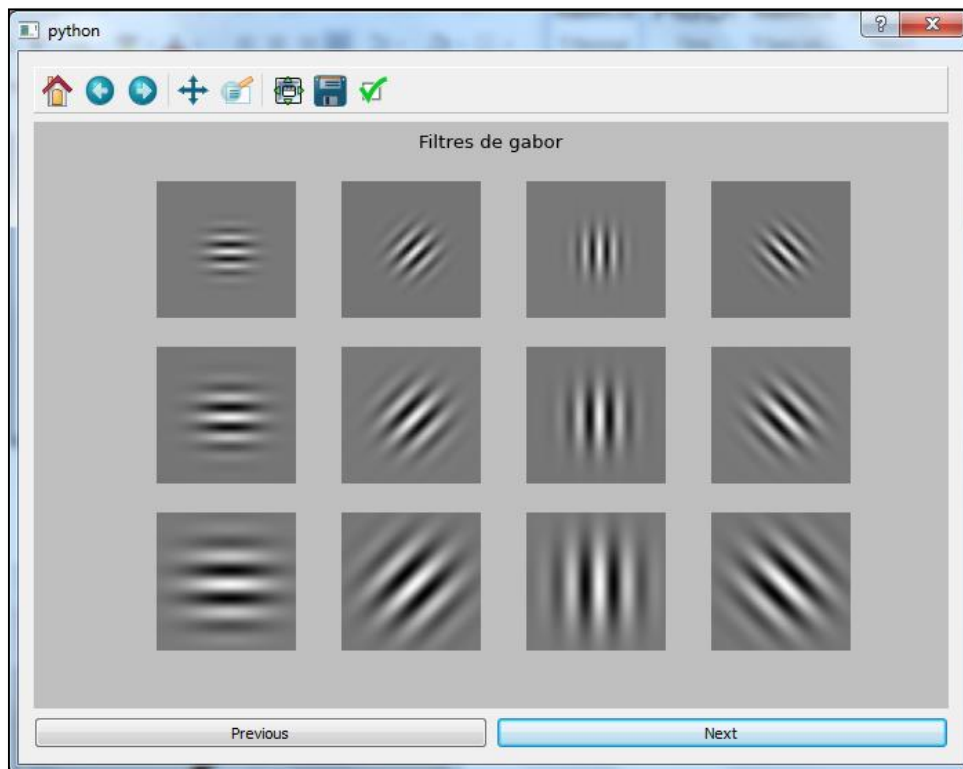


Figure 67: les filtres de gabor utilisés

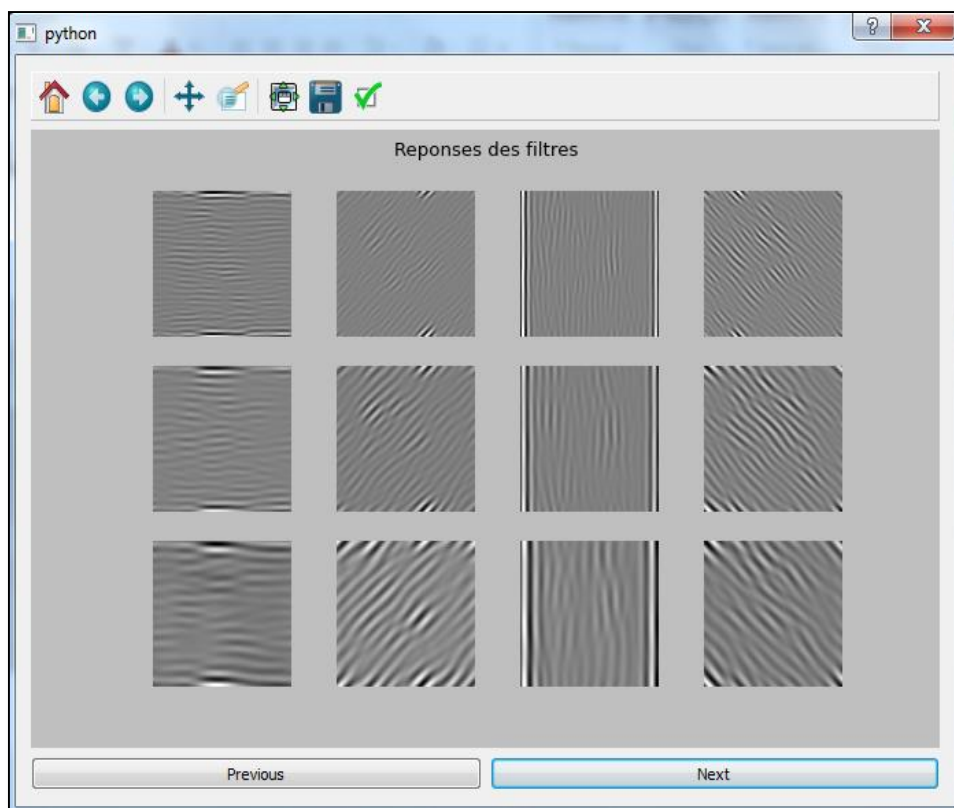


Figure 68 : Les réponses aux filtres de gabor

Implémentation et résultats

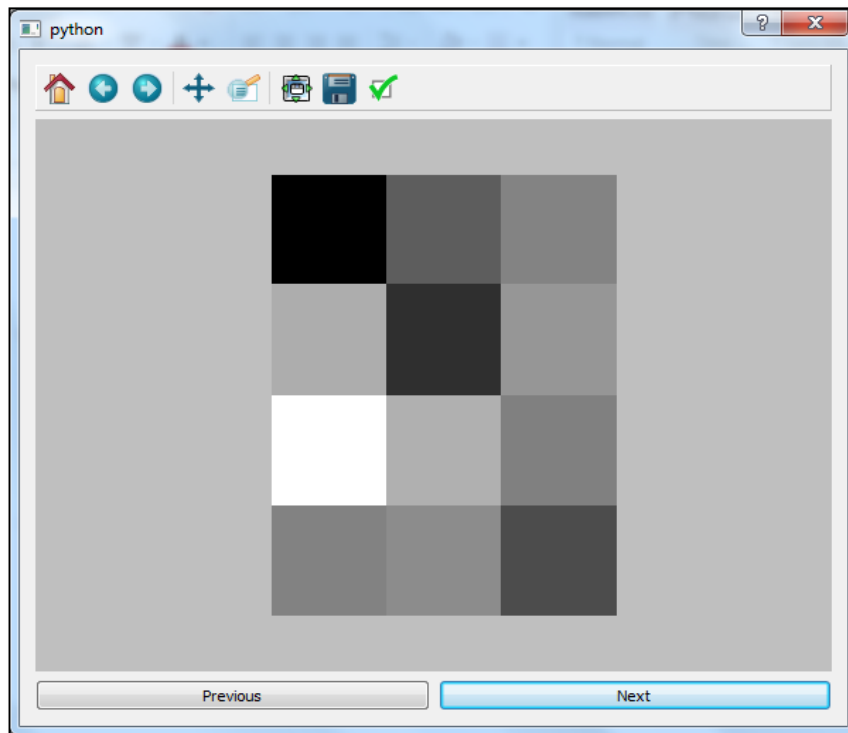


Figure 69 : SGFS d'un pixel

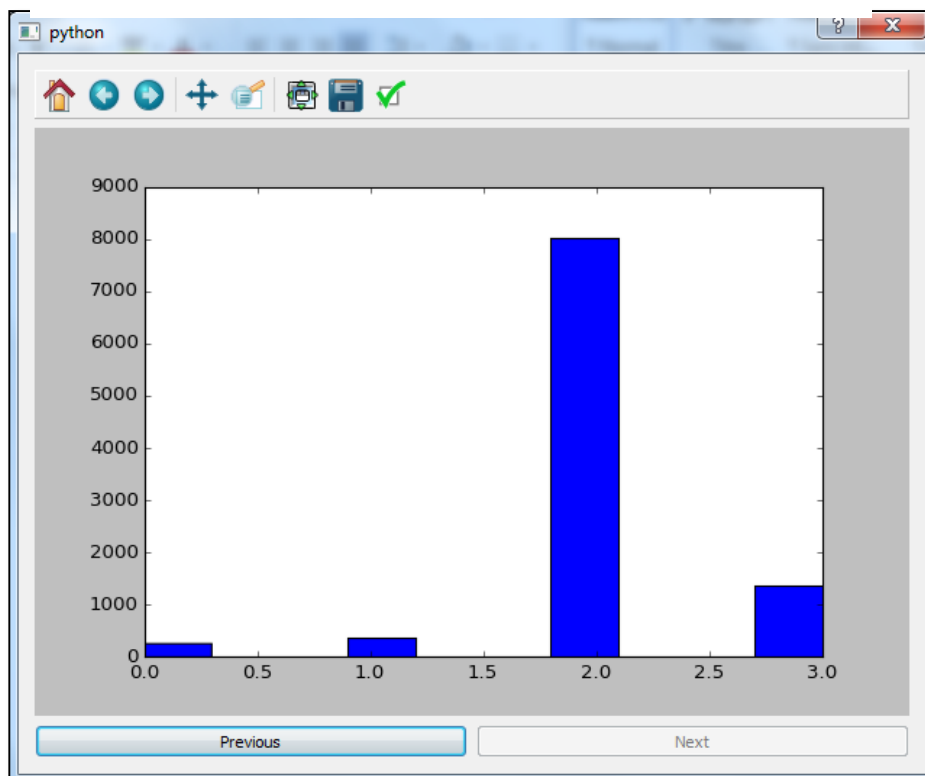


Figure 70 : Histogramme des textons de l'image (vecteur caractéristique)

IV.5.3. Onglet de classification

Finalement l'onglet classification, permet de mettre en place un système intelligent capable de classifier les polypes, en se basant sur des données d'apprentissage, et en sélectionnant un classifieur SVM (Support Vector Machine). L'application donne trois choix du noyau : linéaire, rbf, polynomial.

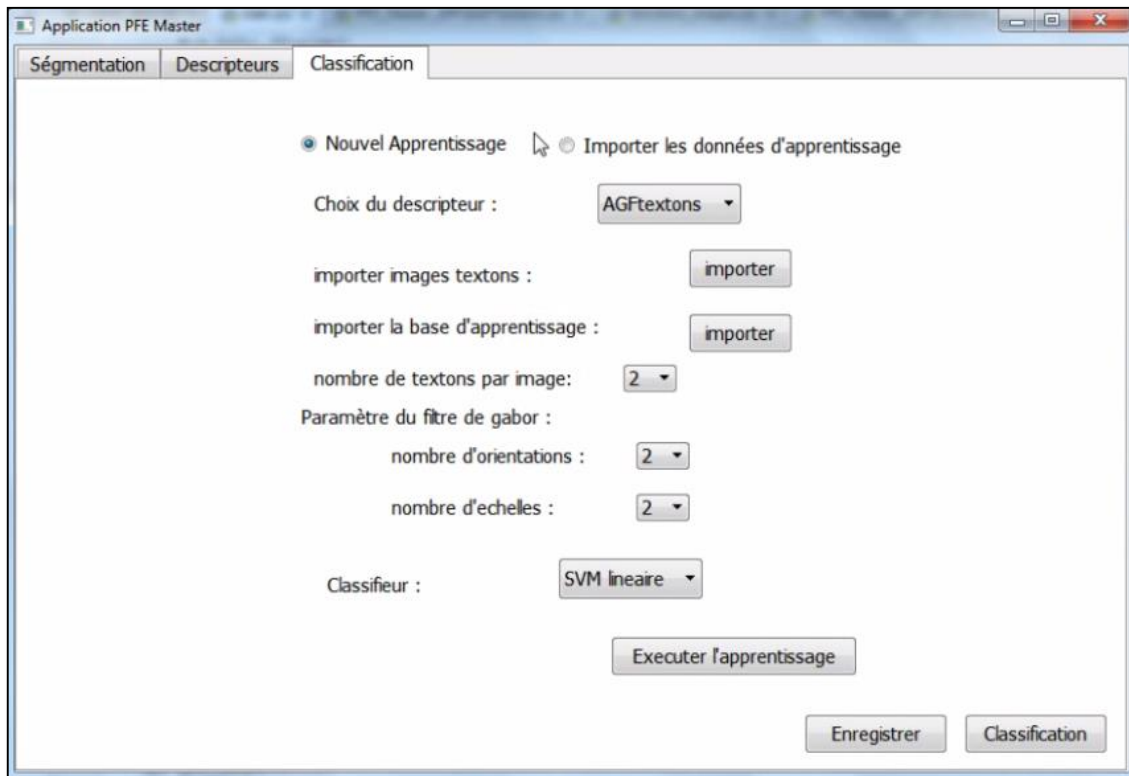


Figure 71: l'onglet classification (partie nouvel apprentissage)

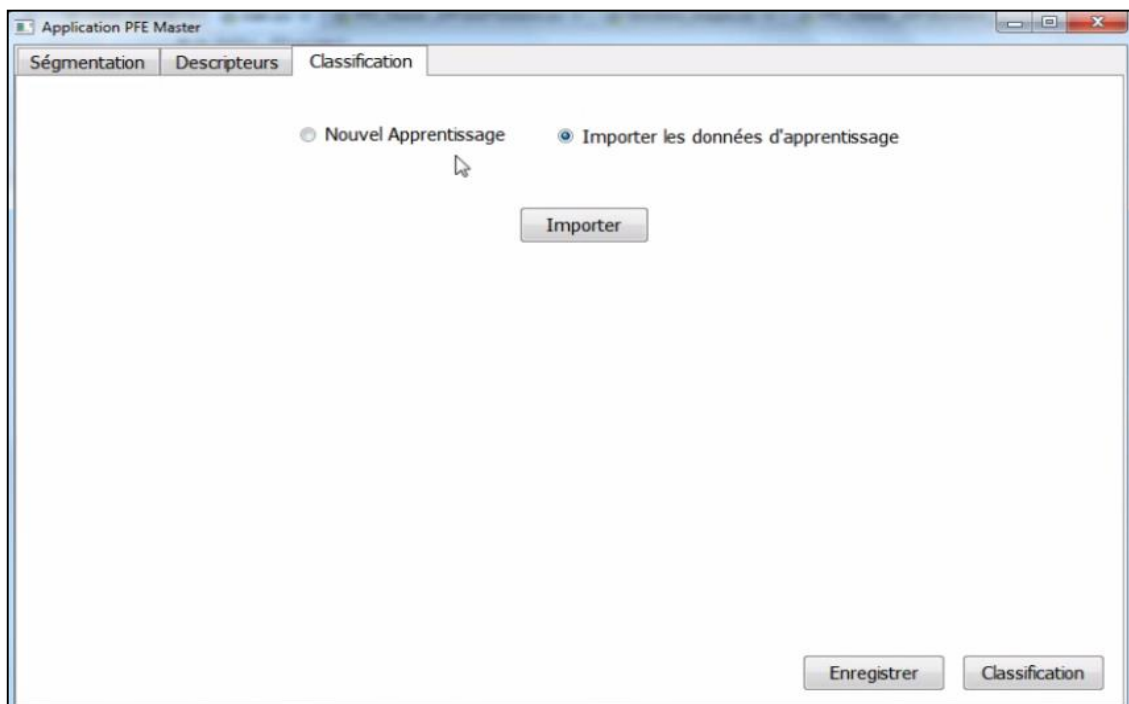


Figure 72 : partie importation des données d'apprentissage

Implémentation et résultats

Comme on le constate d'après la **Figure 71**, et **Figure 72**. On peut opter pour un nouvel apprentissage ou bien importer les données d'apprentissage directement, puis procéder à la classification.

Pour passer à la classification, on appuie sur le bouton « classification ». Une nouvelle fenêtre dialogue s'affiche **Figure 73**. On constate que le résultat de la classification est donné avec des probabilités sur chaque classe. Cela nous permet de savoir à quel point notre classifieur est sûr de l'appartenance de l'image à une certaine classe.

Dans le cas de l'image de la figure on remarque, que les probabilités sont assez proches et par conséquent nous devons remettre en question cette classification, car elle n'est pas sûre. Par contre si nous obtenant des probabilités au-dessus de 75% pour une classe, nous pouvons dire que l'image lui appartient.

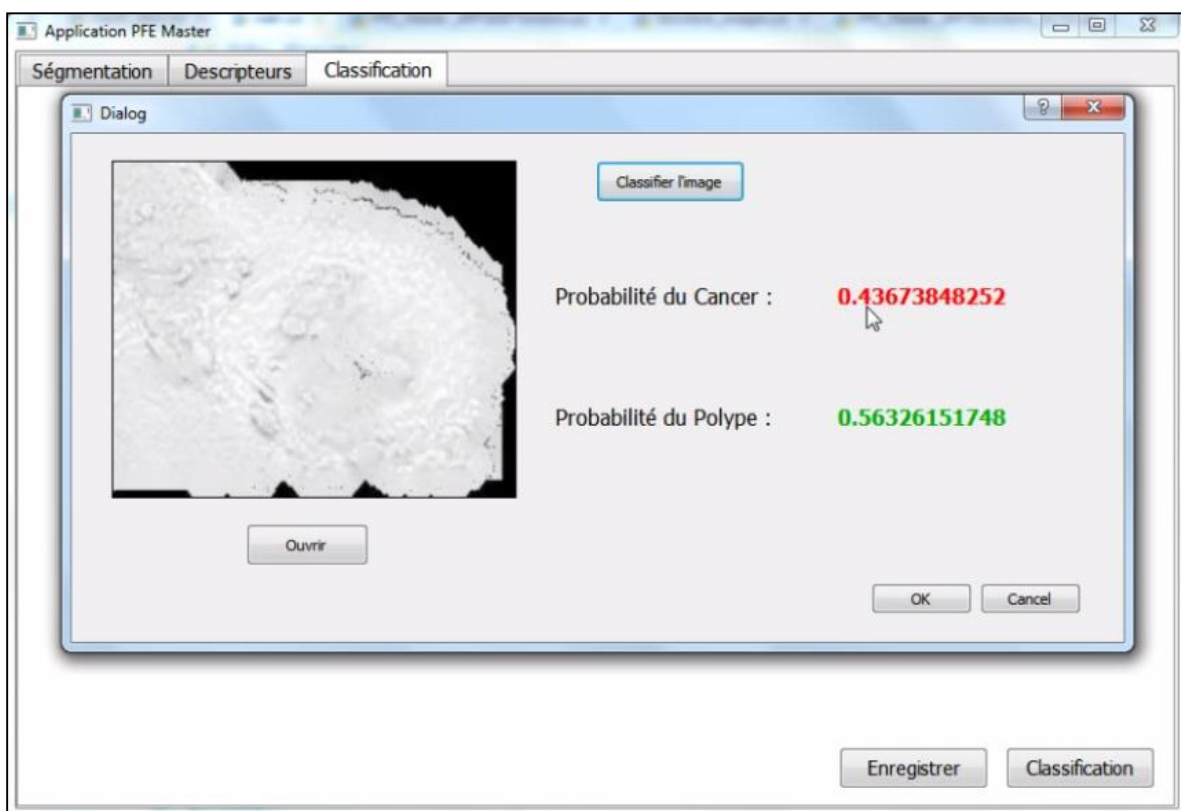


Figure 73 : Fenêtre de la classification d'une image (polype bénin ou malin)

IV.6. Conclusion

Dans ce chapitre nous avons implémenté les quatre méthodes (AGFtextons, AGF_AHT, ACTDtextons, ACTD_AHT) afin de tester la robustesse de chacune. D'après les résultats obtenus nous déduisant que l'approche AHT donne moins de performance par rapport à l'approche des textons. Or, vu sa faible complexité de calcul, nous pouvons l'améliorer afin d'atteindre une meilleur classification tout en préservant le privilège du temps.

Conclusion et perspectives

Avant de traiter directement notre sujet principal, nous avons jugé nécessaire de faire une recherche, tout d'abord sur les techniques d'imagerie médicale les plus utilisées. Chaque technique est mise en œuvre selon la précision qu'elle donne de l'image de l'organe en question. Les techniques que nous avons citées sont classées selon ce critère-là, et par conséquent la coloscopie et la mieux adaptée car nous avons besoin du maximum d'informations sur la texture et la couleur. Ces deux informations ne sont pas suffisamment claires dans les autres approches.

Afin de bien maîtriser notre problématique, nous avons établi une recherche sur les polypes. Leurs caractères morphologiques nous renseignent sur la manière dont nous devons procéder afin de les extraire de l'image endoscopique, tout en prenant en considération la texture et la couleur qui jouent un rôle capital. D'un autre côté il fallait faire une recherche sur les différentes natures des polypes (hyperplasique, adénomateux, et cancéreux) Pour cela, nous avons trouvé plusieurs travaux à ce niveau. Les plus célèbres sont les cryptes de *Kudo et al* et les cryptes de *H.Mittoka*, qui classifient les polypes selon leurs textures. Vu que notre système n'est pas basé sur la chromoendoscopie, nous avons réduit le problème à une classification binaire qui permet de distinguer entre les polypes bénins et malins, et ensuite évaluer le résultat.

Connaissant les informations sur lesquelles nous devons nous appuyer, nous avons pu orienter notre recherche, d'un part sur les méthodes de classification s'appuyant sur l'analyse de la texture. Et d'autre part, la recherche sur les méthodes qui ont pour but la segmentation se basant sur la texture et la couleur. Nous avons choisi la méthode d'invariance par autocorrélation sur les filtres de gabor (AGF [33]), comme méthode de base pour former notre méthode de classification des polypes. Puis nous nous sommes intéressés au descripteur de *Buades et al* [29] utilisé pour la segmentation.

Nous avons proposé une nouvelle technique de classification se basant sur un descripteur de *Buades et al* (au lieu de Gabor). Nous avons essayé d'implémenter les deux approches, ACTD_AHT et celle basée sur l'algorithme des textons ACTDtextons, de l'article de base. Notre approche nous a permis de gagner en temps de calcul par rapport à la méthode initiale. Mais il faut chercher à l'améliorer afin qu'elle soit plus précise et plus performante.

Conclusion et perspectives

Du côté de la segmentation, notre approche s'est basée sur l'information du rouge dans l'image afin de délimiter les zones susceptibles de contenir un polype, ensuite nous avons opté pour une analyse de texture pour chaque zone avec l'algorithme de *Buades et al.* Ce qui nous donne exactement l'endroit où se trouve le polype.

Notre travail s'est donc, plutôt concentré sur la séparation entre polypes cancéreux et polypes normaux, à partir des images endoscopiques ordinaires. Ceci n'est pas le travail final, car le vrai défi réside dans la détection des polypes adénomateux ayant des structures bien précises afin de déterminer les degrés de dangerosité d'un polype. Pour cela il faudra penser à améliorer le descripteur de texture en ajoutant l'information de la couleur, qui joue un rôle très important.

Si ce but est atteint, nous pourrions remplacer la chromoendoscopie par un système informatisé capable de détecter n'importe quelle texture en se basant sur l'apprentissage des pit pattern de *Kudo* ou de *H.Mitooka*.

Quant à la segmentation, dans la majorité des cas l'approche que nous avons mise en place arrive à extraire efficacement la zone où le polype est situé, si nous donnons les bons paramètres de la fenêtre de la médiane et de la valeur du seuil. Afin d'automatiser le processus, nous devons améliorer notre système, pour lui permettre de choisir automatiquement et efficacement les paramètres, en mettant en place des fenêtres adaptatives pour chaque pixel de l'image.

Références :

- [1] « X-ray (Radiography) ». [En ligne]. Disponible sur: <http://www.radiologyinfo.org/en/submenu.cfm?pg=xray>. [Consulté le: 01-juin-2016].
- [2] R. S. of N. A. (RSNA) and A. C. of R. (ACR), « Ultrasound (Sonography) ». [En ligne]. Disponible sur: <http://www.radiologyinfo.org/en/info.cfm?pg=genus>. [Consulté le: 01-juin-2016].
- [3] « Les types d'échographies | Fondation contre le Cancer ». [En ligne]. Disponible sur: <http://www.cancer.be/les-cancers/jeunes-et-cancer/les-examens/chographie/les-types-d-echographies>. [Consulté le: 01-juin-2016].
- [4] « Le scanner ou tomodensitométrie ». [En ligne]. Disponible sur: <http://www.doctissimo.fr/html/sante/imagerie/scanner.htm>. [Consulté le: 01-juin-2016].
- [5] « MRI Scans: How Do They Work? - Medical News Today ». [En ligne]. Disponible sur: <http://www.medicalnewstoday.com/articles/146309.php>. [Consulté le: 20-juin-2016].
- [6] « Gastroscopy », *Newcastle Surgery*. .
- [7] « Duodénum : définition ». [En ligne]. Disponible sur: <http://www.docteurclic.com/encyclopedie/duodenum.aspx>. [Consulté le: 20-juin-2016].
- [8] « www.ensta-paristech.fr/~manzaner/Cours/IAD/AM_Segmentation.pdf ». .
- [9] « glotin.univ-tln.fr/MCBIR/Segmentation_images_principes.pdf ». .
- [10] R. Adams et L. Bischof, « Seeded region growing », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 16, n° 6, p. 641-647, juin 1994.
- [11] I. N. Manousakas, P. E. Undrill, G. G. Cameron, et T. W. Redpath, « Split-and-Merge Segmentation of Magnetic Resonance Medical Images: Performance Evaluation and Extension to Three Dimensions », *Comput. Biomed. Res.*, vol. 31, n° 6, p. 393-412, déc. 1998.
- [12] I. Mikić, S. Krucinski, et J. D. Thomas, « Segmentation and tracking in echocardiographic sequences: active contours guided by optical flow estimates », *IEEE Trans. Med. Imaging*, vol. 17, n° 2, p. 274-284, avr. 1998.
- [13] M. A. Hearst, S. T. Dumais, E. Osman, J. Platt, et B. Scholkopf, « Support vector machines », *IEEE Intell. Syst.*, vol. 13, n° 4, p. 18-28, juill. 1998.
- [14] S.-C. Wang, « Artificial Neural Network », in *Interdisciplinary Computing in Java Programming*, Boston, MA: Springer US, 2003, p. 81-100.
- [15] A. J. Izenman, « Linear Discriminant Analysis », in *Modern Multivariate Statistical Techniques*, New York, NY: Springer New York, 2013, p. 237-280.
- [16] R. M. Haralick, K. Shanmugam, et I. Dinstein, « Textural Features for Image Classification », *IEEE Trans. Syst. Man Cybern.*, vol. 3, n° 6, p. 610-621, nov. 1973.
- [17] M. M. Galloway, « Texture analysis using gray level run lengths », *Comput. Graph. Image Process.*, vol. 4, n° 2, p. 172-179, juin 1975.
- [18] A. K. Jain et F. Farrokhnia, « Unsupervised texture segmentation using Gabor filters », 1990, p. 14-19.
- [19] « Video player and/or recorder with Hadamard transform ».
- [20] I. Daubechies, « Orthonormal bases of compactly supported wavelets », *Commun. Pure Appl. Math.*, vol. 41, n° 7, p. 909-996, oct. 1988.
- [21] T. Ojala, M. Pietikainen, et D. Harwood, « Performance evaluation of texture measures with classification based on Kullback discrimination of distributions », in , *Proceedings of the 12th IAPR International Conference on Pattern Recognition, 1994. Vol. 1 - Conference A: Computer Vision amp; Image Processing, 1994*, vol. 1, p. 582-585 vol.1.

Conclusion et perspectives

- [22] T. Ojala, M. Pietikäinen, et D. Harwood, « A comparative study of texture measures with classification based on featured distributions », *Pattern Recognit.*, vol. 29, n° 1, p. 51-59, janv. 1996.
- [23] M. Li, S. M. Ali, S. Umm-a-OmarahGilani, J. Liu, Y.-Q. Li, et X.-L. Zuo, « Kudo's pit pattern classification for colorectal neoplasms: A meta-analysis », *World J. Gastroenterol. WJG*, vol. 20, n° 35, p. 12649-12656, sept. 2014.
- [24] « Polypes et adénomes colorectaux - ADECA 68 ». [En ligne]. Disponible sur: http://www.adeca68.fr/le_cancer_colorectal/histoire_naturelle/polypes_et_adenomes_colorectaux.178.html. [Consulté le: 20-juin-2016].
- [25] « Automatic mango detection using texture analysis and randomised Hough transform », *Appl. Math. Sci.*, 2015.
- [26] Q. Wu, Y. Gan, B. Lin, Q. Zhang, et H. Chang, « An active contour model based on fused texture features for image segmentation », *Neurocomputing*, vol. 151, p. 1133-1141, mars 2015.
- [27] P. F. Felzenszwalb et D. P. Huttenlocher, « Efficient Graph-Based Image Segmentation », *Int. J. Comput. Vis.*, vol. 59, n° 2, p. 167-181, sept. 2004.
- [28] R. Marée, O.-M. Jean-Christophe, et M.-Y. Vannary, « Détection automatique de glomérules en pathologie digitale », sept. 2015.
- [29] A. V. Mamonov, I. N. Figueiredo, P. N. Figueiredo, et Y.-H. Richard Tsai, « Automated Polyp Detection in Colon Capsule Endoscopy », *IEEE Trans. Med. Imaging*, vol. 33, n° 7, p. 1488-1502, juill. 2014.
- [30] A. Buades, T. Le, J.-M. Morel, et L. Vese, « Cartoon+Texture Image Decomposition », *Image Process. Line*, vol. 1, sept. 2011.
- [31] A. R. Yadav, R. S. Anand, M. L. Dewal, et S. Gupta, « Multiresolution local binary pattern variants based texture feature extraction techniques for efficient classification of microscopic images of hardwood species », *Appl. Soft Comput.*, vol. 32, p. 101-112, juill. 2015.
- [32] Z. Zou, J. Yang, V. Megalooikonomou, R. Jennane, E. Cheng, et H. Ling, « Trabecular bone texture classification using wavelet leaders », 2016, vol. 9788, p. 97880E-97880E-6.
- [33] F. Riaz, F. B. Silva, M. D. Ribeiro, et M. T. Coimbra, « Invariant Gabor Texture Descriptors for Classification of Gastroenterology Images », *IEEE Trans. Biomed. Eng.*, vol. 59, n° 10, p. 2893-2904, oct. 2012.
- [34] M. Haghghat, S. Zonouz, et M. Abdel-Mottaleb, « CloudID: Trustworthy cloud-based and cross-enterprise biometric identification », *Expert Syst. Appl.*, vol. 42, n° 21, p. 7905-7916, nov. 2015.
- [35] « JPEG 2000: How does it work? » [En ligne]. Disponible sur: http://faculty.gvsu.edu/aboufateh/web/wavelets/student_work/ef/how-works.html. [Consulté le: 22-mai-2016].
- [36] « Image Processing : Edge Detection ». [En ligne]. Disponible sur: <http://www.owlnet.rice.edu/~elec539/Projects97/morphjrks/moredge.html>. [Consulté le: 22-mai-2016].
- [37] « Ingrid Daubechies: Ten Lectures on Wavelets, SIAM 1992 ».
- [38] T. Ojala, M. Pietikäinen, et T. Maenpää, « Multiresolution gray-scale and rotation invariant texture classification with local binary patterns », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, n° 7, p. 971-987, juill. 2002.
- [39] M. Pietikäinen, T. Ojala, et Z. Xu, « Rotation-invariant texture classification using feature distributions », *Pattern Recognit.*, vol. 33, p. 43-52, 2000.
- [40] I. Oulu, *The Local Binary Pattern Approach to Texture Analysis – Extensions and Applications*. 2003.

Conclusion et perspectives

- [41] Z. Tang, Y. Su, M. J. Er, F. Qi, L. Zhang, et J. Zhou, « A local binary pattern based texture descriptors for classification of tea leaves », *Neurocomputing*, vol. 168, p. 1011-1023, nov. 2015.
- [42] M. D. Ribeiro, A. M. R. da C. Pereira, et C. A. da S. Lopes, « Clinical, endoscopic and laboratorial assessment of patients with associated lesions to gastric adenocarcinoma: development of a follow-up model », s.n., Porto, 2005.
- [43] R. Singh, G. Anagnostopoulos, K. Yao, H. Karageorgiou, P. Fortun, A. Shonde, K. Garsed, P. Kaye, C. Hawkey, et K. Ragnath, « Narrow-band imaging with magnification in Barrett's esophagus: validation of a simplified grading system of mucosal morphology patterns against histology », *Endoscopy*, vol. 40, n° 6, p. 457-463, juin 2008.
- [44] J.-K. Kamarainen, V. Kyrki, et H. Kalviainen, « Invariance properties of Gabor filter-based features-overview and applications », *IEEE Trans. Image Process.*, vol. 15, n° 5, p. 1088-1099, mai 2006.
- [45] M. Varma et A. Zisserman, « A Statistical Approach to Texture Classification from Single Images », *Int. J. Comput. Vis.*, vol. 62, n° 1-2, p. 61-81, avr. 2005.
- [46] B. S. Manjunath et W. Y. Ma, « Texture features for browsing and retrieval of image data », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 18, n° 8, p. 837-842, août 1996.
- [47] J. MacQueen, « Some methods for classification and analysis of multivariate observations », présenté à Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics, 1967.
- [48] Y. Meyer, *Oscillating Patterns in Image Processing and Nonlinear Evolution Equations: The Fifteenth Dean Jacqueline B. Lewis Memorial Lectures*. Boston, MA, USA: American Mathematical Society, 2001.
- [49] « Welcome to Python.org », *Python.org*. [En ligne]. Disponible sur: <https://www.python.org/>. [Consulté le: 07-juin-2016].
- [50] O. Regniers, L. Bombrun, D. Guyon, J. C. Samalens, et C. Germain, « Wavelet-Based Texture Features for the Classification of Age Classes in a Maritime Pine Forest », *IEEE Geosci. Remote Sens. Lett.*, vol. 12, n° 3, p. 621-625, mars 2015.
- [51] F. Albrechtsen, *Statistical Texture Measures Computed from Gray Level Cooccurrence Matrices*. 2008.
- [52] L. Wang et D.-C. He, « Texture classification using texture spectrum », *Pattern Recognit.*, vol. 23, n° 8, p. 905-910, janv. 1990.