République Algérienne Démocratique et Populaire Ministère de l'Enseignement Supérieur et de la Recherche Scientifique Université Mouloud MAMMERI, Tizi-Ouzou



# Faculté de Génie Electrique et d'Informatique Département d'Automatique

# Mémoire de Fin d'Etudes

En vue de l'obtention du diplôme

D'Ingénieur d'Etat en Automatique

# Thème

# Segmentation d'image basée sur la technique de seuillage flou

Proposé par et dirigé par :

Mr HAMMOUCHE.K

Devant le jury composé de : Président :Mr MESSAR.Y Promoteur : Mr HAMMOUCHE.K Examinateur : Mlle AIT AIDER.M Examinateur : Mme BOUDJEMAA.F

Soutenu le : 13 /07 / 2010

Présenté par :

KECHIR Mokrane KERCHIT Mohammed

Promotion 2010

### <u>DEDICACES</u>

Je dédie ce modeste travail à ma chère mère, mon cher père qui m'ont offert tous leurs amour, et qu'ont sacrifié juste pour ma réussite.

A mes frères et sœurs : Djaffer, Akli, Nabil, Safia, et Lynda.

A tous mes amis et collègues d'études.

A tous ceux qui me sont cher(e)s.

Mokrane.

# <u>DÉDICACE</u>

A toi ma très chère mère qui a sacrifié sa vie pour ses enfants, que dieu te garde pour nous.

A la mémoire de mon père.

A mes très chers frères Aziz, Assia et Numidia.

A toute ma famille.

A tous mes proches grands et petits.

A tous mes amis chacun son nom.

A tous ceux qui m'ont aidé de prés ou de loin dans mes études.

Je dédie ce modeste travail.

Mohand.

## <u>REMERCIEMENTS</u>

Nous remercions tous les membres de jury. Nous tenons à remercier notre promoteur Mr HAMMOUCHE Kamel en lui exprimant notre sincère reconnaissance pour son aide et ses conseils tout au long de ce travail. Sans oublie Mr MAIDI, Mr GARMAH et Mlle CHILALI pour leur aide. Nos remerciements à nos familles ainsi que tous nos amis pour leurs soutiens et leurs encouragements.

Dieu merci.

Mohand et Mokrane.

## <u>Sommaire</u>

Introduction générale1	
Chapitre I : Généralités sur le traitement d'image	
I.1 Notions sur l'image et le traitement d'image	7
I.1.1 Introduction	7
I.1.2 Définition de l'image	7
I.1.3 Image numérique	7
I.1.4 Caractéristiques d'une image numérique	8
I.1.4.1 Pixel	8
I.1.4.2 Dimension	9
I.1.4.3 Résolution	9
I.1.4.4 Luminance	10
I.1.4.5 Contraste	
I.1.4.6 Contour	11
I.1.4.7 Connexité	11
I.1.4.8 Histogramme d'une image	
I.1.4.9 Bruit	
I.1.4.10 Texture	
I.1.4.11 Entropie associe à une image	14
I.2. Etapes d'analyse d'images	17
I.2.1 Acquisition d'images	17
I. 2.1.1 Caméra à tubes	17
I. 2.1.2 Caméras CCD	
I. 2.2 Numérisation	
I. 2.2.1 Echantillonnage	
I. 2.2.2 Quantification	
I. 2.2.3 Codage (binaire)	21
I. 2.3 Prétraitements des images	
I.2.3.1 Modification d'histogramme	
I.2.3.2 Egalisation d'histogramme	

I.2.3.3 Filtrage	23
I.2.3.3.1 Filtrage global	23
I.2.3.3.2 Filtrage local	23
I.2.3.3.3 Le filtrage local linéaire	23
I.2.3.3.4 Filtrage local non linéaire cal Non-Linéaire	24
I.3 Segmentation d'image	24
I.3.1 Les différentes techniques de segmentation d'image	24
I.3.1.1 Approches non coopératives	26
I.3.1.1.1 Détection de contours	26
I.3.1.1.2 Extraction de région	27
I.3.1.1.2.1 Segmentation par croissance de région	27
I.3.1.1.2.2 Segmentation par division-fusion	27
I.3.1.1.2.3 Segmentation par classification	28
I.3.1.1.3 Seuillage	29
I.3.1.2 Approches coopératives	30
I.4 Méthodes de seuillage	31
I.4.1 Approche globale	32
I.4.1.1 Méthodes basées sur la transformation d'histogramme	33
I.4.1.2 Méthodes basées sur la théorie d'information	34
I.4.1.3 Méthode basée sur l'analyse discriminante	35
I.5 Conclusion	37

#### Chapitre II : Logique floue en segmentation d'image

41
41
41
41
42
42
42

II.2.1.3.3 Hauteur	42
II.2.1.3.4 α-coupe	43
II.2.1.3.5 Cardinalité	43
II.2.1.4 Géométrie floue	43
II.2.1.4.1 La surface	44
II.2.1.4.2 Le périmètre	44
II.2.1.4.3 La compacité	44
II.2.1.4.4 La hauteur et la largeur	44
II.2.1.4.5 Connexité dans les ensembles flous	45
II.2.1.5 Opérations sur les ensembles flous	45
II.2.1.5.1 Complément	45
II.2.1.5.2 Inclusion	
II.2.1.5.3 Egalité	46
II.2.1.5.4 Union	46
II.2.1.5.5 L'intersection	46
II.2.1.5.6 Propriétés de l'union et de l'intersection	46
II.2.1.5.6.1 Intersection ou T-norme	46
II.2.1.5.6.2 Union ou T-conorme	47
II.2.1.6 Exemple de fonction d'appartenance	47
II.2.1.6.1 Fonction d'appartenance trapézoïdale	47
II.2.1.6.2 Fonction d'appartenance exponentielle	48
II.2.1.6.3 Fonction d'appartenance gaussienne	48
II.2.1.6.4 Fonction d'appartenance singleton	49
II.2.1.7 Variable linguistique	49
II.2.1.8 Règles linguistiques	50
II.2.1.9 Structure générale d'un système flou	51
II.2.1.10 Procédure de raisonnement flou	52
II.2.1.10.1 Fuzzification	52
II.2.1.10.2 Base de règles floues	
II.2.1.10.3 Raisonnement flou	52
II.2.1.10.4 Défuzzification	

II.3 Systèmes et modèles flous type-2	
II.3.1 Concept des ensembles flous type-2	53
II.3.1.1 Exemple	
II.3.2 Types d'ensembles flous type-2	55
II.3.2.1 Ensemble type-2 Gaussien	55
II.3.2.2 Ensemble type-2 Intervalle	55
II.3.2.3 Ensemble type-2 Triangulaire	55
II.3.3 Représentation des ensembles flous type-2	56
II.3.4 Opérations sur les ensembles flous type-2	57
II.3.5 Opérations algébriques	
II.3.5.1 Multiplication	58
II.3.5.2 Addition	
II.3.6 Système flou type-2	59
II.3.6.1 Fuzzification	59
II.3.6.2 Règle	59
II.3.6.3 Réduction de type	60
II.3.6.4 Déffuzification	61
II.4 Conclusion	61

## **Chapitre III : Seuillage flou**

III.1 Introduction	65
III.2 Indices de flou d'une image	65
III.2.1 Indice de flou	66
III.2.2 Distance de Hamming ou linéaire	66
III.2.3 Distance euclidienne ou quadratique	66
III.3 Degré d'appartenance	68
III.4 L'utilisation des indices de flou	72
III.4.1 Méthode de Chaira et Ray	73
III.4.2 Méthode de seuillage de Huang et Wang	73
III.4.3 La méthode de seuillage de Pal	75

III.5 Méthode basée sur l'algorithme FCM	75
III.5.1 Méthode Jawahar et al	77
III.6 Seuillage basée sur l'entropie floue	
III.6.1 Méthode de Chang et al	
III.6.2 Méthode de Tao et al	79
III.6.3 Méthode de Lin et al.	
III.6.4 Méthode de Braviano	
III.6.5 Seuillage entropique de Shanbag	
III.7 Maximisation de la divergence floue	
III.8 L'utilisation des mesures de probabilités	87
III.8.1 Non paramétrique	
III.8.2 Paramétrique	
III.8 Conclusion	

#### **Chapitre VI : Tests et résultats**

VI.1 Introduction	
VI.2 Critères de comparaison des résultats	93
VI.2.1 Uniformité	93
VI.2.2 Divergence entre l'image originale et sa version seuillée	94
VI.3.1 Domaines d'application	95
VI.3.1.1 Médical	95
VI.3.1.2 Industrie	
VI.3.1.3 Sécurité	
VI.3.1.4 Astronomie	106
VI.3.2 Etude de la méthode de Jawahar	110
VI.4 Conclusion	112
Conclusion générale	115
Bibliographie.	

# <u>Introduction</u> <u>Générale</u>

#### **Introduction Générale**

L'information visuelle est son doute la plus riche des différentes sources d'information disponibles. De ce fait la conception d'un système de reconnaissance des formes pour l'extraction des objets dans une image suscite un intérêt sans cesse croissant.

De nombreux chercheurs se son penche sur ce problème et ont mit en œuvre plusieurs approches en vue de la conception d'un système de reconnaissance des formes efficace.

L'objectif de la plus part des systèmes de reconnaissance des formes est de décrire l'importante quantité d'information contenu dans l'image en cherchant des indices visuel ou des primitives adéquates, permettant de la représentée sous une forme plus réduite et facilement exploitable en séparant les objets de l'image par la segmentation.

Le cadre général dans lequel s'inscrit cette thèse est celui de la segmentation d'image en utilisant la technique de seuillage qui constitue la base de la majorité des processus de binarisation d'image.

Dans le procède de seuillage, plusieurs raisonnement peuvent être utilisées tels que les probabilités, les statistiques, l'entropie, la logique flou...etc.

Dans cette étude on utilise le raisonnement flou comme outil de base pour le seuillage, qui est une logique multivalente qui considère et manipule l'information incomplète telle que l'incertitude et l'imprécision, fondée sur l'idée d'appartenance d'un élément à plusieurs classes en même temps. L'imprécision dans une image peut s'exprimé soit en termes d'ambiguité d'appartenance d'un pixel à l'objet ou au fond (s'il est noir et blanc) soit au niveau de l'indéfinition de la forme et de la géométrie d'une région dans une image, soit de l'association des deux facteurs précédent. Nous allons introduire des mécanismes de la logique floue en segmentation d'image avec l'objectif d'obtenir des résultats plus précis à travers une stratégie de segmentation qu'est le seuillage.

Dans le chapitre I nous allons exposer des généralités sur l'image ainsi que les principales étapes et techniques du domaine le plus vaste d'analyse d'image à savoir le processus de segmentation.

Dans le chapitre II nous allons aborder les notions fondamentales des ensembles floues en décrivant leurs caractéristiques, les opérations sur les ensembles floues et leurs propriétés dans chacune des deux catégories à savoir, système flou type-1 et système flou type-2. Les techniques de seuillage flou ainsi que les différents outils utilisés dans ce dernier seront présenté dans le chapitre III.

Le chapitre VI sera réservé pour la présentation et l'interprétation des résultats obtenus par les différents testes effectue sur les algorithmes implémentés.

# <u>Chapitre I</u>: Généralité sur le traitement d'image.

#### I.1 Notions sur l'image et le traitement d'image

#### **I.1.1 Introduction**

Avec la parole, l'image constitue l'un des moyens les plus importants qu'utilise l'homme pour communiquer avec autrui. C'est un moyen de communication universel dont la richesse du contenu permet aux êtres humains de tout âge et de toute culture de se comprendre. C'est aussi le moyen le plus efficace pour communiquer, chacun peut analyser l'image à sa manière, pour en dégager une impression et d'en extraire des informations précises.

De ce fait, le traitement d'images est l'ensemble des méthodes et techniques opérant sur celles-ci, dans le but de rendre cette opération possible, plus simple, plus efficace et plus agréable, d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées pertinentes.

#### I.1.2 Définition de l'image

L'image est une représentation d'une personne ou d'un objet par la peinture, la sculpture, le dessin, la photographie, le film,... etc. C'est aussi un ensemble structuré d'informations qui, après affichage sur l'écran, on a signification pour l'œil humain. Elle peut être décrite sous la forme d'une fonction I(x, y) de brillance analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et I est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation.

#### I.1.3 Image numérique

Contrairement aux images obtenues à l'aide d'un appareil photo, ou dessinées sur du papier, les images manipulées par un ordinateur sont numériques (représentées par une série de bits). L'image numérique est l'image dont la surface est divisée en éléments de tailles fixes appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleur prélevé à l'emplacement correspondant dans l'image réelle ou calculé à partir d'une description interne de la scène à représenter.

#### I.1.4 Caractéristiques d'une image numérique [1], [4]

L'image est un ensemble structuré d'informations caractérisé par les paramètres suivants:

#### I.1.4.1 Pixel

Contraction de l'expression anglaise "*Picture élément* "c.-à-d élément d'image, le pixel est le plus petit point de l'image, c'est une entité calculable qui peut recevoir une structure et une quantification. Si le bit est la plus petite unité d'information que peut traiter un ordinateur, le pixel est le plus petit élément que peuvent manipuler les matériels et logiciels d'affichage ou d'impression. La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure ci-dessous :



Fig I.1 : Représentation des pixels d'une image.

La quantité d'information que véhicule chaque pixel donne des nuances entre images monochromes et images couleurs. Dans le cas d'une image monochrome, chaque pixel est codé sur un octet, et la taille mémoire nécessaire pour afficher une telle image est directement liée à la taille de l'image.

Dans une image couleur (R.V.B.), un pixel peut être représenté sur trois octets : un octet pour chacune des couleurs : rouge (R), vert (V) et bleu (B).

#### I.1.4.2 Dimension

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes L de cette matrice multiplié par le nombre de colonnes K nous donne le nombre total  $L^*K$  de pixels dans une image.

#### Exemple :



Fig I.2 : Image numérique et ses différents paramètres

#### I.1.4.3 Résolution [2]

C'est la clarté ou la finesse de détails atteinte par un moniteur ou une imprimante dans la production d'images. Sur les moniteurs d'ordinateurs, la résolution est exprimée en nombre de pixels par unité de mesure (pouce ou centimètre). On utilise aussi le mot résolution pour désigner le nombre total de pixels affichables horizontalement ou verticalement sur un moniteur, plus grand est ce nombre, meilleure est la résolution.



Fig I.3 : Echelle de différents types de résolutions

#### I.1.4.4 Luminance

C'est le degré de luminosité des points de l'image. Elle est aussi définie comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface pour un observateur lointain. Le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet.

#### I.1.4.5 Contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images. Si L1 et L2 sont les degrés de luminosité respectivement de deux zones voisines A1 et A2 d'une image, le contraste C est défini par le rapport :

$$C = \frac{L1 - L2}{L1 + L2}$$
(I.1)

Une bonne visualisation se caractérise par :

• Une bonne luminosité (brillante).

• Un bon contraste : il faut éviter les images où la gamme de contraste tend vers le blanc ou le noir, ces images entraînent des pertes de détails dans les zones sombres ou lumineuses.

• L'absence de parasites.

#### I.1.4.6 Contour

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Un contour peut être défini comme une marche d'escalier s'il est net, comme une rampe s'il est flou ou comme un toit s'il s'agit d'une ligne sur un fond uniforme. La *figure (I.4)* montre le contour d'une image.



Fig I.4 : Contour d'une image

#### I.1.4.7 Connexité

La connexité est une propriété de la liaison entre deux pixels qui fait qu'on les considère comme faisait partie de la même région dans une image et supposant que deux pixels P et Q vérifie déjà un certaine critère de similarité. On peut définir différents types de connexité.

• 4-connexité : les deux pixels sont deux voisins tels que Q est un des 4-voisins de P



• 8-connexité : les deux pixels sont deux voisins tels que Q est un des 8-voisins de P



• connexité mixte : soient P et Q sont 4-voisins, ou bien P et Q sont voisins diagonaux et aucun des 4-voisins communs à P et Q ne sont 4-connexes.

#### I.1.4.8 Histogramme d'une image [3]

L'histogramme est la fonction qui donne la fréquence d'appartenance de chaque niveau de gris ou de couleur, l'histogramme nous renseigne sur la distribution des niveaux de gris. Il offre beaucoup d'informations. Il peut être utilisé afin de diminuer l'erreur de quantification dans la comparaison de deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image. Ainsi l'analyse d'une image numérique début le plus souvent par le calcul et l'analyse de son histogramme.

La figure (1.5) montre un exemple d'une image et son histogramme :



Fig I.5 : Image et son histogramme.

On distingue ainsi trois types d'histogramme selon la forme

**Histogramme uni modal :** Il est forme d'un seul mode correspondant à un seul pic, il représentera alors soit un objet soit un fond.

**Histogramme bimodal :** Il est forme de deux modes bien séparés, on dit qu'il est bimodal. On déduit ainsi que l'image contient un objet et un fond.

**Histogramme multimodal :** Il est constitue de plusieurs modes, ou plusieurs pics séparés par des vallées. Il indique la présence de plusieurs objets.

#### I.1.4.9 Bruit

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage, des dispositifs optiques et électroniques du capteur.

#### I.1.4.10 Texture [5]

Malgré la diversité et le nombre important des travaux consacrés à l'étude de la texture, la définition précise de celle-ci n'est toujours pas donnée. La difficulté principale provient du fait que la texture est étroitement liée à la perception visuelle humaine et par conséquent contient une composante subjective se prêtant mal à une formalisation.

La définition la plus répondue détermine la texture comme étant une région de l'image dont l'observateur se traduit par une impression visuelle d'homogénéité pour toutes les transitions possibles à l'intérieur de cette région. Elle traduit une répartition spatiale d'un même motif dans différentes directions de l'espace. Ceci lui attache donc deux dimensions sur la base desquelles on peut la décrire. La première concerne le motif élémentaire constituant la texture. La seconde implique la distribution spatiale de ces motifs.

Un motif élémentaire est un ensemble connexe de points caractérisé par des propriétés de nature quantitatives telles que les moments, l'entropie et l'énergie entre autres et par des propriétés géométriques comme sa forme, sa surface, etc....

La répartition spéciale des motifs nécessite la définition d'une fonction permettant la prise en compte des inters corrélations ou d'un ensemble de règles de placement des motifs sur le support bidimensionnel.

On distingue généralement deux types de textures : les structurelles ou macro textures (*Fig I.6*) et les textures statistiques ou micro texture (*Fig I.7*).

Dans la première, on décède un motif de base



Fig I.6 : Textures de forme structurelle.

La deuxième est probabiliste est caractérisée par l'aspect anarchique et homogène, qui ne comprend ni de motif localisable, ni de fréquence de répétition principale.



Fig I.7 : Texture de forme statistique

Les approches les plus fréquemment rencontrées dans l'analyse de la texture peuvent être classées en deux grandes classes : l'approche statistique et l'approche structurelle.

Il existe toutefois des méthodes qui combinent les deux approches en tenant compte à la fois de la microscopie et la macroscopie de certaines textures. Par exemple, dans le cas de la texture des sillons d'un champ de végétation, l'arrangement des sillons sera caractérisé par une approche structurelle alors que l'état de surface de la végétation sera modélisé par une approche statistique. Ces observations sous entendent une action importante qui est celle de l'existence d'une échelle de résolution à laquelle les textures peuvent être analysées d'une façon optimale. L'aspect microscopique correspond aux hautes résolutions et l'aspect macroscopique aux basses résolutions.

#### I.1.4.11 Entropie associe à une image [28]

La notion d'entropie est très utilisée en traitement d'image. C'est une caractéristique très importante car elle est liée à la mesure d'incertitude et la quantité d'information.

#### a/ L'entropie comme mesure d'incertitude

Etant donné une expérience dont le résultat avant sa réalisation est inconnue, mais pour laquelle nous pouvons décrire l'ensemble des tous les résultats possibles, il s'ensuit que cette expérience contient une certaine incertitude qui sera éliminée après sa réalisation.

Comment pourrions-nous mesurer cette incertitude? Etant donné que nous connaissons les probabilités a priori de chacun des événements qui caractérisent le résultat de l'expérience, il est déjà possible de prévoir que l'incertitude associée à des événements équiprobables est supérieure à celle associée au cas où il y a des événements qui ont une probabilité d'occurrence plus grande que d'autres, ou au cas extrême où il y a un élément dont la probabilité est égale à 1. Dans ce dernier cas, l'incertitude associée à l'expérience est nulle.

L'incertitude sur une expérience dépend donc des probabilités attachées aux différents résultats possibles.

Shannon, en 1948, a donné l'expression qui fournit l'incertitude associée à un ensemble fini  $E = \{e_1 \ e_2, \ \dots, \ e_k\}$  d'événements indépendants où *pi* est la probabilité d'occurrence de chaque événement *s<sub>i</sub>*. La mesure d'incertitude associée à s est calculée par :

$$H(p_1, p_2, \dots, p_k) = -\sum_{i=1}^k p_i \log_2(p_i)$$
(I.2)

Avec :

$$\sum_{i=1}^{k} p_i = 1$$
 (I.3)

 $H(p_1, p_2, ..., p_k)$  est appelée entropie. Elle possède les propriétés suivantes :

P1: 
$$H(p_1, p_2, ..., p_k) \ge 0$$

P2:  $H(p_1, p_2, ..., p_k) = 0 \text{ si } \exists i \mid p_i = 1$ 

P3: 
$$H(p_1, p_2, ..., p_k) \leq H(\frac{1}{k}, \frac{1}{k}, ..., \frac{1}{k})$$

P4: 
$$H(p_1, p_2, ..., p_k) = H(p_1, p_2, ..., p_k, 0)$$

#### P5: H(A, B) = H(A) + H(B) si A et B sont deux expériences indépendantes

En choisissant la base 2, l'expression de l'entropie utilise l'incertitude d'une expérience ayant deux événements équiprobables ( $E = \{e_1, e_2\} où p1 = p2 = 0.5$ ) comme unité de mesure. Cette unité de mesure s'appelle *bit (binary unit)*. La formule (*I.2*) donne alors le nombre de bits nécessaires pour coder l'expérience. Il faut remarquer que le choix de la base 2 pour le logarithme n'est pas essentiel car il est possible de passer d'une base à une autre à l'aide de la propriété suivante :

$$\log_a b = \log_a c \cdot \log_c b.$$

La formule (I.2) peut s'exprimer alors (en utilisant comme base pour le logarithme le nombre d'éléments de S) à un facteur constant près, comme :

$$H(p_1, p_{2, \dots, p_k}) = -\log_2(k) \sum_{i=1}^k p_i \cdot \log_k(p_i)$$
(I.4)

Dans la suite de ce travail, on utilisera avec cette expression sans tenir compte de la constante.

#### b/ L'entropie comme mesure d'information

Lorsque nous connaissons le résultat d'une expérience, nous pouvons aussi être intéressés par la quantité d'information qui caractérise ce résultat. Nous voudrons donc mesurer la quantité d'information que nous recevons lorsqu'une expérience a eu lieu et que nous connaissons le résultat.

Une information est considérée comme telle si et seulement si elle élimine une certaine incertitude, d'où le lien très étroit entre information et incertitude. On peut dire que plus l'incertitude est grande au début d'une expérience, plus l'information que l'on obtient à la fin est grande.

Du fait que l'information supprime une incertitude, la mesure d'incertitude (I.4) peut être aussi utilisée pour quantifier l'information obtenue [29]. Dans ce cas, le sens de variation de l'incertitude est opposé au sens de variation de l'information. La différence entre ces deux interprétations consiste seulement dans le fait que nous pouvons nous placer soit avant la réalisation de l'expérience (où l'équation (I.1) mesure l'incertitude des événements de l'espace de probabilité des solutions possibles), soit après que cette expérience ait eu lieu (dans ce dernier cas l'équation (I.1) mesure la quantité d'information obtenue).

#### c/ L'entropie d'une d'image

Soit une image représentée en  $N_G$  niveaux de gris  $(0, l_1, ..., N_G-1)$  et composée de M pixels. Soit  $f_i$  la fréquence de chacun des  $N_G$  niveaux de gris et pi = fi/M la probabilité associée à chacun de ces niveaux. D'après l'équation (I.4), la quantité d'information associée à cette source de données est :

$$H(p_1, p_2, \dots, p_{N_G-1}) = \sum_{i=0}^{N_G-1} p_i . \ln p_i$$
(I.5)

La notion d'entropie est utilisée en analyse d'images pour segmenter des images de manière à maximiser la qualité de l'information retenue. Elle peut être utilisée pour mesure le comportement statistique d'un pixel dans la classe à laquelle il appartient, en analyse de la texture ou encore pour le seuillage.

#### I.2. Etapes d'analyse d'images

Le processus d'analyse d'images peut être défini comme l'ensemble de méthodes et d'outils permettant de décrire quantitativement le contenu d'une image. Il est généralement décomposé en plusieurs étapes : acquisition, numérisation, prétraitement, segmentation, interprétation comme le montre le schéma ci-dessous :



Fig I.8 : Cycle d'analyse d'image

#### I.2.1 Acquisition d'images

Tout système de traitement d'images peut être vu comme la combinaison de deux étapes : l'acquisition et le traitement proprement dit. La qualité des résultats du système dépend bien sur

de l'algorithme mis en place et de son adéquation au problème posé, mais aussi de la qualité initiale des images. Ici nous allons montrer deux outils d'acquisition d'images et expliquer brièvement leurs principes de fonctionnement :

#### I. 2.1.1 Caméra à tubes

Ces capteurs sont relativement anciens et font appel à l'archéologie électronique puisqu'ils ont étés inventés en 1931 par *Vladimir Zworykin*. Leur principe (*Fig 1.9*) est le suivant : la scène est projetée sur une cible photosensible qui convertit une quantité de lumière en une quantité de charge. Il se forme ainsi un relief de potentiel correspondant à l'image analysée sur la cible. Celle-ci est l'anode du tube dont la source électronique est la cathode. Les électrons issus de la cathode sont attirés par l'anode polarisée positivement. Ce flux d'électrons est dévié par l'ensemble des bobines de déviation afin de scruter l'ensemble de la cible rectangulaire à analyser. Le courant issu de la cible correspond à l'image projetée. L'amplitude du courant est fonction de l'éclairement.



Fig I.9 : Principe de fonctionnement de la camera a tube

#### I. 2.1.2 Caméras CCD

Ces capteurs sont relativement récents. Leur principe (*Fig I.10*) est le suivant : la scène est projetée au moyen d'un objectif sur un réseau de capteurs discret, ce qui réalise un échantillonnage spatial de l'image. Chaque photo-élément convertit l'énergie lumineuse en énergie électrique. Il existe deux types de capteurs : les photodiodes ou les condensateurs MOS

de type P. Dans les deux cas, l'arrivée de photons conduit à la formation d'une charge électrique sous la photodiode ou le *photomos*.

Pour réaliser le transfert de charge, les condensateurs MOS sont associés les uns à la suite des autres. Le substrat des semi-conducteurs ainsi que l'isolant est commun. Les grilles métalliques sont indépendantes pour chaque capteur. Le but consiste à transférer successivement les charges électriques présentes sous les différentes grilles vers la sortie.



Fig I.10 : Principe de fonctionnement de la caméra CCD

#### I. 2.2 Numérisation [4]

La numérisation est la conversion d'un signal analogique en un signal numérique. Elle se déroule en 3 étapes : L'échantillonnage, la quantification et le codage. C'est conceptuellement une modélisation mathématique de la réalité. La *figure (I.11)* ci-dessous donne un exemple illustratif sur les différentes étapes de numérisation :



Fig I.11 : Différentes étapes de numérisation d'image

#### I. 2.2.1 Echantillonnage

L'échantillonnage consiste à remplacer une fonction continue dans le temps ou dans l'espace par la suite des valeurs qu'elle prend en des instants ou des zones discret(e)s périodiques. Ces valeurs suffiront pour reconstituer la fonction dans une étape ultérieure. Les valeurs du signal sont prises régulièrement à une période d'échantillonnage  $T_e$ .



Dans le cas des images qui sont des signaux 2-D (deux dimensions), l'échantillonnage se fait selon les dimensions spatiales « x » et « y » (et non pas selon le temps comme précédemment).

Donc l'échantillonnage est le procédé de discrétisation spatiale d'une image consistant à associer a chaque zone rectangulaire R(x, y) d'une image continue une unique valeur I(x, y). On parle dessous échantillonnage lorsque l'image est déjà discrétisée et qu'on diminue le nombre d'échantillons. Une image numérique est une image échantillonnée et quantifiée.

#### I. 2.2.2 Quantification

La quantification consiste à accorder pour chaque échantillon une valeur numérique. Dans le cas des images, chaque échantillon représente un pixel, donc la quantification accorde pour chaque pixel un niveau de gris, généralement contenu entre 0 et 255, c-à-dire que la luminance de l'image et quantifiée sur un intervalle contenant 256 niveaux de gris. Chaque niveau étant alors codé sur 8 bits (*code binaire naturel*).

Ainsi l'image qui était au départ comme signal continu est discrétisée pour être représentée sous forme de pixels avec des valeurs numériques représentant le niveau de gris de chaque pixel, ces valeurs sont contenues dans l'intervalle [0 255].

Donc la quantification désigne la limitation du nombre de valeurs différentes que peut prendre I(x, y), tel qu'il est illustré dans l'exemple suivant :



Fig I.12 : Exemple sur l'échantillonnage et la quantification

#### I. 2.2.3 Codage (binaire)

Les niveaux de quantification sont codés sous la forme d'un mot binaire sur k bits.  $2^k$  niveaux sont alors possibles.

Dans le cas ou l'intervalle de représentation est de 0 à 255, le codage se fait sur 8 bits.

Les images au nivaux de gris sont représentées sur l'intervalle [0 255], et pour les images couleur qui ont trois composantes de base, chaque valeur d'une composante est représentée sur l'intervalle [0 255] donc au totale les niveaux de quantification seront codés sur  $3 \ge 24$  bits.

#### I. 2.3 Prétraitements des images [6]

Le prétraitement a pour but d'améliorer la qualité de l'image en rehaussant son contraste ou en éliminant le bruit par filtrage. Cette étape précédée en générale celle de la segmentation. Elle permet ainsi de facilite la segmentation en améliorant la ressemblance entre les pixels qui appartient a la même région, ou en appuyant la dissemblance entre les pixels qui appartiennent a des régions déférentes, lorsque il s'agit d'une segmentation basée sur l'approche région.

Il existe beaucoup de méthodes de prétraitement d'image ici nous allons présenter quelque techniques élémentaires.

#### I.2.3.1 Modification d'histogramme [6]

C'est la technique de l'expansion de dynamique qui consiste à exploiter au mieux l'échelle de niveaux de gris disponible sur le système d'acquisition d'image. Le principe est le suivant :

Soient  $a_s$  [*i*,*j*] l'image de départ (image représentée en niveau de gris) et  $a_s$  '[*i*,*j*] l'image après transformation. Soient [ $a_0$ ,  $a_1$ ] l'intervalle des intensités présentes dans l'image et [ $a_{min}$ ,  $a_{max}$ ] l'intervalle disponible, c'est-à-dire que si les données (niveaux de gris) sont codées en 8 bits on aura l'intervalle disponible qui varie entre [0, 2<sup>8</sup>-1]= [0, 255]. L'expansion de la dynamique correspond à la transformation linéaire suivante :

$$a_s' = \alpha + \beta * a_s$$

Telle que :

 $\forall a \in [a_0, a_1] \quad a \stackrel{T}{\longrightarrow} a' \in [a_{\min}, a_{\max}]$ 

Avec :

$$\alpha = (a_{\min} * a_1 - a_{\max} * a_0) / (a_1 - a_0) ; \beta = (a_{\max} - a_{\min}) / (a_1 - a_0)$$

#### I.2.3.2 Egalisation d'histogramme

L'égalisation d'histogramme à pour but d'harmoniser la répartition des niveaux de l'image, de telle manière à tendre un même nombre de pixel pour chacun des niveaux de l'histogramme. Cette opération vise ainsi à augmenter les nuances dans l'image.

#### I.2.3.3 Filtrage [6], [7]

Le principe du filtrage est de modifier la valeur des pixels d'une image, généralement dans le but d'améliorer son aspect. En pratique, il s'agit de créer une nouvelle image en se servant des valeurs des pixels de l'image d'origine.

#### I.2.3.3.1 Filtrage global

Chaque pixel de la nouvelle image est calculé en prenant en compte la totalité des pixels de l'image de départ. Dans cette catégorie on trouve, par exemple, les opérations sur les histogrammes ou les opérations qui nécessitent de passer dans l'espace de Fourier.

#### I.2.3.3.2 Filtrage local

Chaque pixel de la nouvelle image est calculé en prenant en compte seulement un voisinage du pixel correspondant dans l'image d'origine. Il est d'usage de choisir un voisinage carré et symétrique autour du pixel considéré.

#### I.2.3.3.3 Le filtrage linéaire

Le filtre local est dit linéaire si la valeur du nouveau pixel est une combinaison linéaire des valeurs des pixels du voisinage.

Nouvelle Valeur<sub>x,y</sub> = 
$$\sum_{i,j} A_{i,j} * P_{x+i,y+j}$$
 (I.6)

Ai, j : valeur, entière ou réelle, spécifique au filtre linéaire

Pour le filtre moyen par exemple les Ai, j sont tous égaux à 1

#### I.2.3.3.4 Filtrage local non linéaire

Si le filtre ne peut pas être exprimé par une combinaison linéaire, il est appelé " nonlinéaire ". Les filtres non-linéaires sont plus complexes à mettre en œuvre que les filtres linéaires. Cependant les résultats obtenus avec les filtres non-linéaires sont très souvent de meilleure qualité que ceux obtenus par les filtres linéaires.

Comme exemple d'un filtre non linéaire, on peut citer le filtre médian. Celui-ci consiste à modifier le niveau de gris d'un pixel par le niveau de gris correspondant à la médiane des pixels voisins, ordonnés dans l'ordre croissant.

#### I.3 Segmentation d'image

L'étape de segmentation est une étape très importante dans la chaine d'analyse d'images; car c'est à partir de l'image segmentée que les mesures sont effectuées sur les objets que contient l'image.

La segmentation consiste a effectue un partitionnement d'une image en plusieurs régions homogènes par apport a un ou plusieurs attributs (niveau de gris, attributs de texture, couleur). Les régions obtenues se distinguent par des différences significatives selon ces mêmes attributs.

#### I.3.1 Les différentes techniques de segmentation d'image [8], [9]

Il existe une très grande diversité de techniques de segmentation que l'on peut classer en deux principales catégories : les approches non coopératives et les approches coopératives.

- Dans la catégorie des approches non coopératives on peut distinguer trois types de méthodes :
  - Les méthodes adaptées à l'extraction des régions homogènes.
  - Les méthodes pour de détection de contour.
- Les approches coopératives combinent les méthodes de la première catégorie avec celles de la détection de contour.



#### I.3.1.1 Approches non coopératives

#### I.3.1.1.1 Détection de contours [10]

Contrairement aux approches de segmentation par extraction de régions qui recherchent les zones de l'image qui vérifient des propriétés d'homogénéité au sens d'un ou de plusieurs critères, les méthodes de segmentation par détection de contours recherchent les discontinuités des intensités lumineuses ou des ruptures de modèles de textures.

Les contours se manifestent dans une image par une forte transition des valeurs d'intensité. La détection de ces variations s'opère généralement selon deux catégories. Dans la première catégorie se trouvent les techniques qui emploient un filtre de type différentiel ou adaptatif. Elles sont fondées sur la recherche des points de l'image présentant un fort gradient, une forte courbure ou encore une forte corrélation avec un profil prédéfini. Les techniques qui n'utilisent pas le filtrage sont essentiellement basées sur l'utilisation des outils de la programmation dynamique, la morphologie mathématique, les approches probabilistes et autres.

#### a/ Définition du contour actif

Le contour actif est formé de points mobiles répartis sur une courbe, en deux dimensions, fermée ou ouverte, à extrémités fixes ou non. Il est placé à proximité de la zone d'intérêt dans une image, se déplace et se réforme afin d'épouser les contours des objets comme est illustré cidessous.



Fig I.13 : Initialisation et évolution du contour actif

Cette évolution est itérative, décrite par des équations basées sur la notion d'énergie interne correspondante aux caractéristiques de la courbe, et l'énergie externe dépendante de l'image ellemême.

#### b/ Segmentation par Level Sets

La méthode d'ensembles de niveau zéro (*Level sets*) est une méthode de simulation numérique utilisée pour l'évolution des courbes et des surfaces dans les domaines discrets. La formulation des contours actifs par les ensembles de niveau zéro (*Level Sets*) permet d'implémenter les contours actif tout en gérant le problème de changement de topologie, de plus son extension aux dimensions supérieures et aisée. Le principe de cette méthode est le suivant :

Cette méthode permet de faire évoluer une courbe paramétrique fermée C(p) suivant une équation du type  $\frac{\partial C}{dt} = FN$  ou *t* est le temps, *F* est la vitesse d'évolution et *N* est la normale unitaire à la courbe. Chaque point de la courbe *C* évolue suivant la direction normale à la courbe avec une vitesse F telle qu'il est illustré dans la figure suivante :



Fig I.14 : Formulation des contours actifs par les ensembles de niveau zéro (Level Sets).

L'avantage principal de cette méthode est la possibilité de gérer automatiquement le changement de topologie de la courbe en évolution. La courbe C peut être divisée en deux ou trois courbes, inversement plusieurs courbes peuvent êtres fusionnées et devenir une seule courbe.

#### I.3.1.1.2 Extraction de région

#### I.3.1.1.2.1 Segmentation par croissance de région

Elle permet de sélectionner un pixel ou un ensemble de pixels de l'image, appelé noyau, ou germe autour duquel on fait croitre une région. Ce pixel est généralement choisi de manière optimale au sens d'un critère qui peut nécessiter l'utilisation des résultats de segmentation antérieurs. Dans ce cas l'image est divisée en petites zones de niveau uniforme. Les zones adjacentes sont alors fusionnées en des régions si elles satisfont un critère de similitude.

#### I.3.1.1.2.2 Segmentation par division-fusion

Dans cette catégorie de segmentation trois grandes familles de méthodes sont distinguées : a/ Approches par division

Cette méthode consiste à diviser l'image, qui constitue la région initiale, en région de plus en plus homogènes. Le processus est réitéré pour chacune des régions produites jusqu'à ce qu'une certaine homogénéité soit atteinte. L'homogénéité d'une région est souvent contrôlée par sa variance ou son contraste. Ces techniques à caractère descendant ont une faiblesse liée à la nature souvent régulière du découpage. Une région est divisée en sous-régions de niveaux inférieurs, les frontières d'une région sont alors représentées sur différents niveaux. Leurs délimitations exactes sont ainsi difficiles à obtenir.

Beaucoup d'algorithmes de division reposent sur l'utilisation des histogrammes de niveaux de gris. Les régions sont alors définies à partir des intervalles entre les vallées.

#### b/ Approches par fusion

L'idée consiste à exploiter une partition initiale de l'image constituée de petites régions. Puis ces régions sont fusionnées successivement jusqu'à ce que le critère de fusion ne soit plus vérifie. Plusieurs règles de regroupement ont été proposées. Certaines de ces règles mettent en jeu :

- Des propriétés statistique telles que la moyenne ou la variance des niveaux de gris des régions, le gradient moyen des frontières de régions, le contraste maximum des régions, ou d'autres statistiques locales qui expriment l'état de surface des régions, etc.

- Des propriétés géométriques ou morphologiques telle l'élongation ou la compacité des régions. Deux régions sont regroupées si par exemple un facteur de forme est conservé ou amélioré après leur fusion.

#### c/ Approches par division-fusion

Ces méthodes combinent les deux approches précédentes : la division qui partitionne l'image en zones localement homogènes, puis la fusion des régions similaires au sens d'un prédicat de regroupement. Ces deux opération sont répétées jusqu'à ce qu'elles ne soient plus possibles.
### I.3.1.1.2.3 Segmentation par classification

Elle consiste à regrouper les pixels de niveaux semblables, indépendamment des relations de connexité qui peuvent les lier. La technique de seuillage d'histogrammes, qui constitue la majorité des méthodes de segmentation par classification, s'appuie sur l'hypothèse que les régions de niveau de gris uniforme produisent des modes suffisamment significatifs dans les histogrammes de l'image pour que l'on puisse les caractériser directement par les valeurs limites des pixels qui les composent. Il suffit alors de seuiller l'image entre ces deux limites pour en extraire les régions.

Les problèmes de classification s'attachent à déterminer des procédures permettant d'associer une classe à un objet (individu). Ces problèmes se déclinent essentiellement en deux variantes : la classification dite supervisée et la classification dite non supervisée (automatique).

### a/ Classification supervisée

Ces sont des méthodes dans lesquelles les classes sont connues a priori avant d'effectuer l'opération d'identification des éléments de l'image. Elles demandent une première phase d'apprentissage sur l'échantillon représentatif dans le but d'apprendre les caractéristiques de chaque classe et une deuxième phase pour décider de l'appartenance d'un individu à telle ou telle classe. Les données segmentées de l'ensemble d'apprentissage proviennent d'un étiquetage manuel des images ou des régions d'intérêt en *C* classes de tissus  $(C_1 \dots C_c)$  par un ou plusieurs experts. Chaque classe *Ci* se voit donc affecter un ensemble d'apprentissage *Ei*, et les données de l'ensemble de test sont segmentées en fonction des  $E_i$ . Parmi ces méthodes on peut citer : la segmentation *Bayésienne*, la segmentation par les champs de *Markov*, réseaux de neurones, etc.

### b/ Classification non supervisée

L'intérêt des méthodes non supervisées est qu'elles ne nécessitent aucune base d'apprentissage et par là même aucune tâche préalable d'étiquetage manuel n'est requise. La seule intervention de l'expert se situe à la fin du processus pour identifier les tissus par exemple en comparant les classes calculées avec les classes biologiques. Les algorithmes non supervisés les plus répandus tendent à minimiser une fonction coût, dépendant de la distance de chaque pixel aux prototypes (ou noyaux) des classes. Le prototype d'une classe étant un point connu dont l'appartenance à la classe est garantie et où chaque pixel est assigné à la classe qui lui est la plus proche. Selon la certitude de la classification que nous voulons obtenir, et la relation entre les classes. Nous pourrons distinguer plusieurs méthodes de classification dont nous allons faire une étude plus profondément de certaines de ces dernières dans la suite de cette thèse.

# I.3.1.1.3 Seuillage [11]

L'opération dite de « *seuillage simple* », consiste à mettre a zéro tous les pixels ayant un niveau de gris inférieur à une certaine valeur appelée seuil en anglais « *treshold* » et à la valeur maximale les pixels ayant une valeur supérieur. Ainsi, le résultat du seuillage est une image binaire contenant des pixels noire et blanc, c'est la raison pour laquelle le terme de binarisation est parfois employé. Le seuillage permet de mettre en évidence des formes ou des objets dans des images. Toutefois, la difficulté réside dans le choix de seuil à adopter.

### a/ Seuillage globale

Les méthodes de segmentation par seuillage global sont des méthodes qui utilisent la même valeur de niveau de gris pour seuiller une image entière. En général une méthode de seuillage consiste à déterminer la valeur optimale du seuil s en se basant sur certains critères

### b/ Seuillage locale

Dans cette famille de méthodes, on cherche à déterminer pour chaque pixel un seuil en fonction des luminances des pixels voisins.

Une méthode de segmentation par seuillage local consiste à subdiviser l'image en blocs de tailles égales généralement de taille 32x32. Puis un seuil optimal est calcule pour chacun des blocs en utilisant une des méthodes de seuillage globale.

# I.3.1.2 Approches coopératives

Plusieurs approches coopératives de segmentation, fondées sur la prise en compte de différentes formes de représentation de l'image, mais aussi sur l'application de différentes formes de traitement peuvent être rencontrées. Dans le cas général, nous supposons disposer de *Nr* représentation de la même image obtenue soit par des méthodes différentes, soit par la même méthode, mais avec des paramètres différents. Les représentations qui restent le plus souvent manipulées dans la majorité des approches coopératives sont celles des contours et des régions. Ces deux types de primitives se fondent respectivement sur des notions de dissimilarité et de similarité des propriétés de l'image. Elles sont donc théoriquement duales et ont des caractéristiques complémentaires. Toutefois, en pratique, les représentations obtenues à l'aide de chacune de ces méthodes prise séparément ne vérifient que très rarement la complémentarité précédente. Chacune de ces méthodes apporte une contribution partielle au problème, et pour

obtenir de meilleurs résultats il est nécessaire de mettre en œuvre un procédé permettant la coopération de l'information contour et de l'information région, on distingue :

**a**/**Méthodes séquentielles :** Elles combinent différentes méthodes afin d'obtenir le résultat de segmentation final. Chronologiquement, ce type d'approche est apparu afin de combiner les méthodes de détection de contours et de croissance de région.

**b**/ **Méthodes parallèles :** Ces méthodes tentent de combiner ou de fusionner plusieurs résultats de segmentation de la même image en utilisant plusieurs méthodes.

**c/ Méthodes hybrides :** Elles utilisent des concepts plus élaborés telles que la mise en cause de résultats intermédiaires, l'adaptation au contexte et en fonction des résultats obtenus.

### I.4 Méthodes de seuillage

Les méthodes de seuillage peuvent être réparties en deux grandes familles : les méthodes globales et les méthodes locales (*Fig.I.15*) nous allons nous intéresser qu'aux méthodes globales

A chaque élément (point de coordonnées (i, j)) de l'image *I* composée de *M x N* éléments correspond un niveau d'intensité lumineuse *I* (i, j) (appelé niveau de gris) appartenant à l'ensemble  $G = \{g_0, g_1, ..., g_{N_{G-I}}\}$  ou  $N_G$  correspond au nombre total des niveaux de gris.

On définit l'histogramme h des niveaux de gris d'une image comme étant la fonction qui associe à chaque niveau de gris  $g_i$  (i compris entre 0 et  $N_G$ -l) le nombre de pixels de l'image h ( $g_i$ ) qui possèdent cette intensité lumineuse.

La segmentation par seuillage est l'opération qui associe à chaque point de l'image une classe de luminance après comparaison de ses attributs (*niveaux de gris*) à un ou plusieurs seuils. Une étiquette *e* est alors affectée à chacun des points en fonction de la classe d'appartenance.

Si  $p_{ij}$  dénote un point de l'image de coordonnées (*i*, *j*), l'opération de seuillage peut être formalisée par la relation suivante :

$$C(p_{ij}) = e \quad si \quad s_{l-1} \leq A(p_{ij}) < s_l, \qquad l = 1, 2, ..., k$$
(I.7)

ou

 $C(p_{ij})$  correspond au résultat de la classification du point  $p_{ij}$ 

*e* est une étiquette.

 $s_{l-1}$  et  $s_l$  représentent les valeurs des seuils (niveaux de gris).

 $A(p_{ij})$ est une fonction caractéristique du point  $p_{ij}$  (par exemple I (i, j)).kcorrespond au nombre de classes associe à l'image segmentée.Dans le cas de deux classes (fond et objet) :

$$C(pij) = \begin{cases} 1 & \text{si } I(i,j) < s \\ 0 & \text{sinon} \end{cases}$$

D'une façon générale la classification des points de l'image peut s'effectuer de deux manières différentes. Dans le premier cas, les seuils sont déterminés *globalement* pour tous les points de l'image, alors que dans le second cas le calcul des seuils est fait *localement* et de manière adaptative à l'ensemble des points auxquels ils vont être appliqués.

Nous allons passer en revue quelques méthodes des plus utilisées (*Fig. I.15*) pour déterminer les seuils de segmentation.



Fig I.15 : Organigramme des déférentes techniques de seuillage.

# I.4.1 Approche globale

Les méthodes de segmentation par seuillage global sont des méthodes qui utilisent la même valeur du seuil pour seuiller l'image entière. En général, une méthode de seuillage

consiste à déterminer la valeur optimale du seuil  $s^*$  en se basant sur certains critères. Si s est déterminé uniquement à partir des niveaux de gris de chaque pixel, alors on parlera de méthodes de seuillage dépendant du point. Si  $s^*$  est déterminé à partir de propriétés locales sur un voisinage de chaque point, alors on parlera de méthodes de seuillage dépendant de la région (ici la région prend le sens de voisinage). Nous présentons dans cette section quelque méthodes dépendent du point.

Pour des images composées d'un faible nombre de régions de luminances différentes et bien contrastées, l'histogramme des niveaux de gris est multi modal. La segmentation de limage consiste alors à rechercher dans l'histogramme des luminosités ou les vallées qui séparent ses modes. Les classes sont alors définies par les intervalles entre les vallées.



Fig (I.16) : Délimitation des classes par les vallées de l'histogramme.

# I.4.1.1 Méthodes basées sur la transformation d'histogramme

Des méthodes ont été proposées pour améliorer la dynamique de l'histogramme afin de mieux séparer ses vallées de ses modes. Une solution consiste à déterminer l'histogramme des niveaux de gris en ne prenant en compte que les points à faible *gradient* ou *laplacien* [12].

Dans [13], *Watanabe* suggère de sélectionner une valeur de seuil qui maximise la somme des gradients calculée sur tous les points dont le niveau de gris est égal à la valeur du seuil. Cette méthode est basée sur l'idée suivante: le seuil optimal pour la segmentation de limage est celui qui détecte le plus grand nombre de contours à fort contraste et le plus petit nombre de contours à faible contraste. On cherche alors à maximiser l'influence des contours bien contrastés et à minimiser celle des contours peu contrastés en calculant le seuil *s* pour lequel la fonction suivante est maximale.

$$CM(s) = \frac{C(s)}{N(s)} \tag{I.8}$$

N(s) dénote le nombre de points contours détecté par l'application du seuil s :

$$N(s) = \sum_{(i,j) \in A} P(g_i, g_j, s)$$
 (I.9)

Avec A est l'ensemble des couples de points adjacents (i, j) d'intensités respectives  $g_i$  et  $g_j$ ,

avec  $g_i \leq g_j$ , et :

$$p(g_{i}, g_{j}, s) = \begin{cases} 1 si (g_{i} \le s \le g_{j}) \\ 0 sinon \end{cases}$$
(I.10)

C(s) correspond au contraste total détecté par l'application du seuil s:

$$C(s) = \sum_{(i,j) \in A} c(g_i, g_j, s)$$
(I.11)

$$C(g_i, g_j, s) = \begin{cases} \min(s - g_i, g_j - s) & si \quad (g_i \le s \le g_j) \\ 0 & sinon \end{cases}$$
(I. 12)

CM (s) représente le contraste moyen observé aux abords des contours détectes par le seuil s.

La valeur optimale du seuil  $s^* = s$  est telle que  $CM(s^*) = max_{s=1,2,...,s} N_{G-1} CM(s)$ .

# I.4.1.2 Méthodes basées sur la théorie d'information

Beaucoup des méthodes de seuillage basées sur la théorie d'information ont été proposées. Certaines de ces méthodes utilisent uniquement l'entropie de l'histogramme [14], d'autres tiennent compte de la distribution spatiale des niveaux de gris de l'image en introduisant des entropies d'ordres supérieurs [15].Parmi ces méthodes, la plus populaire est celle proposée par *Kapur et al* [14].

# a/ La méthode de Kapur [14]

Dans cette méthode, les deux distributions de probabilité (une pour les objets et une pour le fond) découlent de l'histogramme des niveaux de gris comme suit :

$$\frac{p_0}{p_s}, \frac{p_1}{p_s}, \dots, \frac{p_{s-1}}{p_s}$$
 (I.13)

$$\frac{p_{s+1}}{1-p_s}, \frac{p_{s+2}}{1-p_s}, \dots, \frac{p_{N_G-1}}{1-p_s}$$
(I. 14)

ou s est la valeur du seuil et  $p_s$  défini en comme suite :

$$P_s = \sum_{i=0}^{s} P_i \tag{I.15}$$

on définit l'entropie de chaque classe comme suit :

$$H_b(s) = -\sum_{i=0}^{s} \frac{p_i}{p_s} ln(\frac{p_i}{p_s})$$
(I.16)

$$H_w(s) = -\sum_{i=s+1}^{N_G-1} \frac{p_i}{1-p_s} ln(\frac{p_i}{1-p_s})$$
(I.17)

Le seuil optimal  $s^*$  est défini comme le niveau de gris maximisant de la quantité  $J(S) = H_b(s) + H_w(s):$ 

$$s^* = argmax \{ H_b(s) + H_w(s) \}$$
 (I.18)

avec :  $s \in G$ 

# I.4.1.3 Méthode basée sur l'analyse discriminante

*Otsu* propose dans **[16]** une méthode basée sur l'analyse discriminante. Cette méthode tente de segmenter l'image en k classes en maximisant un critère de séparabilités entre classes. Dans le cas de deux classes  $\Omega_0$  (fond) et  $\Omega_l(objet)$  les relations suivantes permettent de déterminer le seuil s de séparation entre  $\Omega_0$  et  $\Omega_l$ .

Soit  $p_i$  la probabilité d'occurrence (apparition) de niveau de gris  $g_i$ ,  $i = 0, 1, ..., N_G$ -1.

Soient m et  $\sigma$  respectivement la valeur moyenne et l'écart type des intensités de l'image.

Les probabilités qu'un point appartienne à  $\Omega_0$  ou  $\Omega_1$  sont données respectivement par :

$$P_s \quad et \quad 1 - P_s \tag{I.19}$$

 $P_s$ : est la probabilité d'appartenance d'un a la classe  $\Omega$ .

Les valeurs moyennes des intensités calculées dans  $\Omega_0$  et  $\Omega_1$  sont données par :

$$m_T = \sum_{i=0}^{s} i p_i \quad et \quad 1 - m_T$$
 (I.20)

Après normalisation de ces valeurs par la probabilité d'appartenance à chaque classe on obtient :

- Les centres des classes

$$m_0 = \frac{m_T}{P_s}$$
 et  $m_1 = \frac{1 - m_T}{1 - P_s}$  (I.21)

- La variance qui sépare les deux classes  $\Omega_0$  de  $\Omega_1$  est :

$$\sigma_B^2(s^*) = P_s (m_0 - m)^2 + (1 - P_s) (m_1 - m)^2$$
(I.22)

Le seuil s<sup>\*</sup> qui maximise la variance interclasses est alors fourni par la relation :

$$\sigma_B^2(s^*) = \max\left\{\sigma_B^2(s)\right\} \tag{I.23}$$

Avec: 
$$s = 1, ..., N_G - 1$$

# **I.5** Conclusion

Ce chapitre est une introduction dans le monde de l'image numérique et de traitement d'image. Il comporte un ensemble de définitions et d'explications sur l'image numérique et les différentes étapes et techniques de l'analyse d'image. Nous avons superficiellement abordé les techniques les plus répondus en segmentation d'image, en expliquant le principe de chaque approche. Le choix d'une méthode de segmentation dépend de plusieurs paramètres selon la manière de procéder, de la structure de l'image, de sa qualité et de l'objectif que l'on veut attendre.

Il y a lieu de noter qu'à toutes les phases d'analyse d'une image du bruit et des erreurs peuvent être introduites entraînant ainsi à des informations qui peuvent être ambiguës, imprécises et souvent incomplète. Pour prendre en compte toutes ces remarques, on peut faire appel à la théorie de la logique floue qui sera présentée dans le prochain chapitre.

# <u>Chapitre II</u>: Logique floue en segmentation d'image.

# **II.1 Introduction**

La logique floue est une description mathématique d'un processus basée sur la théorie des ensembles flous. Cette théorie introduite en *1965* par le professeur *Lotfi Zadeh* permet de traiter des propositions ou des états par plusieurs niveaux de vérité.

La définition d'un ensemble flou répond au besoin de représenter des connaissances imprécises, soit parce qu'elles sont exprimées en langage naturel par un observateur qui n'éprouve pas le besoin de fournir plus de précisions ou n'en est pas capable, soit parce qu'elles sont obtenues avec des instruments d'observation qui produisent des erreurs de mesure.

Dans ce chapitre nous donnons un aperçu sur les ensembles flous. Les concepts de base, opération et structures des systèmes et des modèles flous sont également présentés.

# II.2 Systèmes et modèles flous type-1

# **II.2.1** Notions fondamentales sur les ensembles flous

# II.2.1.1 Définition d'un ensemble flou [17]

Soit X un espace de points dont l'élément générateur est note par x, c a d,  $X=\{x\}$ . Un sous ensemble flou A dans X est un ensemble défini par sa fonction d'appartenance  $\mu_A(x)$  qui associe a chaque point dans X un nombre réel appartenant à l'intervalle [0 1].

Un sous ensemble flou A de l'univers X est défini par la fonction d'appartenance suivante :

$$\mu_A: X \to [0 \ 1]$$
$$x \to \mu_A(x)$$

Le sous ensemble flou A s'écrira alors :

$$A = \{(x, \mu_A(x)), x \in X\}.$$

 $\mu_A(x)$  est appelée fonction d'appartenance qui désigne le degré d'appartenance de l'élément x aux sous ensemble flou A.

Selon les valeurs de  $\mu_A(x)$ , on distingue trois cas :

$$\mu_A(x) = \begin{cases} 1 & \text{correspond à l'appartenance absolue de } x \text{ à } A. \\ 0 & \text{correspond à la non appartenance absolue de } x \text{ à } A. \\ \in \ ]0 \ 1[ & \text{traduit l'appartenance nuancée de } x \text{ à } A. \end{cases}$$

Dans le cas ou  $\mu_A$  ne prend que des valeurs égales à 0 ou 1, le sous ensemble flou A n'est rien d'autre qu'un sous ensemble classique de X.

# **II.2.1.2 Fonction d'Appartenance**

Dans un domaine discret  $X = \{x_i / i = 1, 2, ..., n\}$  ou continu *X*, un ensemble flou *A* peut être défini par un ensemble de pairs : degré d'appartenance /élément :

$$A = \mu_A(x_1)/x_1 + \mu_A(x_2)/x_2 + \dots + \mu_A(x_n)/x_n$$
 Cas discret  
$$A = \int_x \mu_A(x)/x$$
 Cas continu

Dans un domaine continu, les ensembles flous sont définis analytiquement par leurs fonctions d'appartenance.

# II.2.1.3 Caractéristiques d'un ensemble flou [18]

Diverses notions complémentaires, d'utilisation courante, permettant de mieux distinguer les sous ensemble flous des ensembles classiques.

# **II.2.1.3.1** Noyau

Soit *A* un ensemble flou de l'univers *X*. Le noyau d'un sous ensemble flou *A* de *X*, noté Noy(A) est un sous ensemble ordinaire de *X* dont chaque élément a un degré :

*Noy* (*A*) = {
$$x \in X / \mu_A(x) = 1$$
}

# II.2.1.3.2 Support

Le support du sous ensemble flou A est un sous ensemble classique de X, dont chacun des éléments a un degré d'appartenance non nul par rapport à A, noté *Supp* (A) :

Supp (A) = {
$$x \in X/\mu_A(x) \neq 0$$
 }.

# II.2.1.3.3 Hauteur

La hauteur d'un sous ensemble flou A de X, noté h (A) est la valeur maximale de la fonction d'appartenance, c'est le plus grand degré d'appartenance à A :

$$h(A) = max(\mu_A(x))$$

Un sous ensemble flou est normalisé si h(A)=1.

### **II.2.1.3.4** α-coupe

L'  $\alpha$ -coupe d'un ensemble flou A notée  $A_a$  est un sous ensemble ordinaire de l'univers de discours X dont tout ses éléments possèdent un degré d'appartenance supérieur ou égal a  $\alpha$ :

$$A_{\alpha} = \{x/\mu_A(x) \ge \alpha\} \quad \alpha \in [0 \ 1]$$

La *figure (II.1)* montre la différence entre le noyau, le support et l' $\alpha$ -coupe d'un sous ensemble flou *A* 



**Fig.II.1 :** Noyau, support et  $\alpha$ -coupe d'un ensemble flou

# II.2.1.3.5 Cardinalité

La cardinalité d'un sous ensemble flou A de X est définie par :

$$|A| = \sum \mu_A(x_i)$$
 si X est fini

Pour un domaine continu, la cardinalité sera définie par :

$$|A| = \int \mu_A(x) dx$$

# II.2.1.4 Géométrie floue [19]

Plusieurs concepts et propriétés géométriques venus de la théorie classique des ensembles ont été généralisés au cas flou. Pour simplifier leurs présentations nous noterons la fonction d'appartenance  $\mu_x(x_{mn})$  par  $\mu$  tout simplement.

Considérons que le support de l'ensemble flou en question est borné et que ses sous-ensembles sont constants par morceaux (piecewise constant set).

**II.2.1.4.1 La surface :** Dans un ensemble flou  $\mu$ , elle est définie par :

$$\alpha(\mu) = \int \mu \tag{II.1}$$

Ou l'intégrale est calculée sur région tell que  $\mu \neq 0$ . Lorsque  $\mu$  est constant par morceaux. *X* forme une partition  $X = \bigcup_i X_i$  telle que  $\forall x \in X_i$ ,  $\mu(x) = \alpha_i$ . Dans ce cas  $\mu(x)$  est la somme des surfaces de ces morceaux (régions) où  $\mu$  a des valeurs constantes pondérées par ces dernières, et la frontière entre deux morceaux  $X_i$  et  $X_j$  est une réunion d'arcs rectifiables  $A_{ijk}$ .

**II.2.1.4.2 Le périmètre :** Dans un ensemble flou  $\mu$ , le périmètre est défini par :

$$pr(\mu) = \sum_{\substack{i,j,k \\ i < j}} |\mu_i - \mu_j| \cdot |A_{ijk}|$$
(II. 2)

Ou  $|A_{ijk}|$  est la longueur de l'arc joignant les deux régions *i* et *j* ayant pour valeurs  $\mu_i$  et  $\mu_j$  respectivement.

**II.2.1.4.3 La compacité :** Dans un ensemble flou  $\mu$  ayant une surface  $\alpha(\mu)$  et un périmètre  $pr(\mu)$  la compacité est définie par:

$$Comp(\mu) = \frac{\alpha(\mu)}{pr^2(\mu)}$$
(II.3)

Physiquement, la compacité est la fraction du maximum de surface occupée par l'objet de périmètre *pr*.

**II.2.1.4.4 La hauteur** et la **largeur** d'un ensemble flou  $\mu$  sont ses projections sur des lignes verticale et horizontale respectivement.

$$h(\mu) = \int [max_x \mu(x, y)] dy \tag{II.4}$$

$$l(\mu) = \int [max_{y}\mu(x,y)]dx \qquad (II.5)$$

Où les intégrales sont calculées sur une région telle  $\mu(x, y) \neq 0$ .

### II.2.1.4.5 Connexité dans les ensembles flous

Les opérateurs ensembliste simples se généralisent aisément au cas des ensembles flous, en revanche, il n'en va pas de même pour la connexité. La notion de connexité des ensembles binaires se généralise au cas flou en degré de connexité.

Le degré de connexité entre deux parais P et Q quelconques d'un ensemble flou  $\mu$ , est défini comme suit :

$$C_{\mu}(P,Q) = \max_{L_{P,Q}}[\min_{1 \le i \le n} \mu(P_i)]$$
(II.6)

Ou  $L_{P,Q} = [P_i, ..., P_n]$  est un chemin de  $P = P_l \dot{a} Q = P_n$  dans X.

Nous disons que *P* et *Q* sont connectés dans  $\mu$  si  $C_{\mu}(P,Q) \ge \min\{\mu(P), \mu(Q)\}$ . La relation entre le coût de connexion  $\psi_{\mu}$  et le degré de connexité  $C_{\mu}$  entre deux éléments *P* et *Q* de *X* est représentée par  $\psi_{\mu} = 1 - C_{\mu}$ .

# II.2.1.5 Opérations sur les ensembles flous [18]

### II.2.1.5.1 Complément

Le complément d'un sous ensemble A de X est noté par  $\overline{A}$ . Il est défini à partir de la fonction d'appartenance de A par :

$$\forall x \in X, \, \mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

# **II.2.1.5.2 Inclusion**

Un sous ensemble flous A est inclus dans un sous ensemble flou B si et seulement si pour tout éléments x de X, si  $\mu_A(x) \le \mu_B(x)$ .

$$A \subseteq B \ ssi$$
  $\forall x \in X; \ \mu_A(x) \leq \mu_B(x)$ 

# II.2.1.5.3 Egalité

Soit deux ensembles flous A et B de l'univers X. On dit que A et B sont égaux si les fonctions d'appartenance ont la même valeur en tout point  $x \in X$ .

$$A = B ssi \quad \forall x \in X, \mu_A(x) = \mu_B(x)$$

### II.2.1.5.4 Union

L'union de deux ensembles flous A et B est un ensemble flou C ( $C = A \cup B$ ) dont la fonction d'appartenance est liée à celles de A et B par :

$$\mu_C(x) = max \left[ \mu_A(x), \, \mu_B(x) \right]$$

# **II.2.1.5.5 L'intersection**

L'intersection de deux ensembles flous A et B est un ensemble flou  $C(C=A \cap B)$  tel que sa fonction d'appartenance est donnée par :

$$\mu_C(x) = min \ [\mu_A(x), \ \mu_B(x)]$$

# II.2.1.5.6 Propriétés de l'union et de l'intersection [20]

# II.2.1.5.6.1 Intersection ou T-norme

Une T-norme notée T est une opération binaire sur l'intervalle unitaire, qui vérifie ou moins les axiomes suivants pour tout  $a, b, c \in [0 1]$ :

- ▶ T (a, 1) =a
- $b \le c \implies T(a, b) \le T(a, c)$
- T(a, b) = T(b, a)
- T (a, T (b, c))= T (T (a, b), c)
- ▶ Intersection standard (Zadeh) : T (a, b)=min (a, b)
- Produit algébrique (Intersection probabilistique) : T (a, b)=ab
- Intersection Lukasiewiez (Bold) : T (a, b)= max (0, a+b-1)

# II.2.1.5.6.2 Union ou T-conorme

Une T-conorme notée S est une opération binaire sur l'intervalle unitaire, qui vérifie ou moins les axiomes suivants pour tout *a*, *b*,  $c \in [0 1]$ :

- ▶ S (a, 0) =a
- $b \le c \implies S(a, b) \le S(a, c)$
- $\bullet$  S (a, b)= S (b, a)

٢

- S(a, S(b, c)) = S(S(a, b), c)
- Intersection standard (Zadeh): S (a, b) =max (a, b)
- ▶ Produit algébrique (Intersection probabilistique) : S (a, b)=*a*+*b*-*ab*
- Intersection Lukasiewiez (Bold): S (a, b) = min(1, a+b)

# **II.2.1.6 Exemple de fonction d'appartenance**

Plusieurs fonctions d'appartenance sont utilisées dans la logique des ensembles flous. Les plus répondues sont les fonctions d'appartenance trapézoïdale, exponentielle, gaussienne et singleton.

# II.2.1.6.1 Fonction d'appartenance trapézoïdale

Cette fonction est donnée par l'équation suivante :

$$\mu_{A}(x) = \begin{cases} 0 & si \quad x \le a - c \text{ ou } x \ge b + d \\ x/c + (1 - a/c) & si \quad a - c < x < a \\ 1 & si \quad a \le x \le b \\ -x/d + (1 + b/d) & si \quad b < x < b + d \end{cases}$$

Sa courbe est représentée par la figure (II.2) suivante :



Fig.II.2: Fonction d'appartenance trapézoïdale

Dans le cas ou a=b la fonction est dite triangulaire et sa courbe est représentée par la *figure* (II.3)



Fig.II.3 : Fonction d'appartenance triangulaire

# II.2.1.6.2 Fonction d'appartenance exponentielle

Cette fonction est donnée par la relation suivante :

$$\mu_A(x)_{=} \begin{cases} exp(x-a) & si \ x < a \\ 1 & si \ a \le x \le b \\ exp(-x+b) & si \ x > b \end{cases}$$

Sa courbe est donnée par la figure (II.4) suivante :



Fig.II.4 : Fonction d'appartenance exponentielle

# **II.2.1.6.3** Fonction d'appartenance gaussienne

La fonction est donnée sous la forme :

$$\mu(x, c, \sigma) = \exp\left(-(x - c/2\sigma)^2\right) \tag{II.7}$$

Ou c est le centre de la gaussienne et  $\sigma$  sa largeur.

Sa courbe est donnée par la *figure(II.5)* suivante :



**Fig.II.5 :** Fonction d'appartenance gaussienne.

# **II.2.1.6.4** Fonction d'appartenance singleton

Cette fonction (Fig II.6) telle que :

$$\mu_A(x) = \begin{cases} 1 & si \ x = x_0 \\ 0 & ailleurs \end{cases}$$



Fig.II.6 : Fonction d'appartenance singleton

# II.2.1.7 Variable linguistique [18]

L'ensemble de référence d'un mot du langage naturel s'appelle « *l'univers du discours* » L'univers de discours d'un mot est un ensemble de termes qui évoquent le même concept mais à degrés différents. Il peut être fini ou non fini.

Une variable linguistique représente un état dans le système à règle ou une variable de réglage dans un contrôleur flou. Sa valeur est définie dans des termes linguistiques qui peuvent être des mots ou des phrases d'un langage naturel ou artificiel.

Chaque variable linguistique est caractérisée par un ensemble tel que :

$${x, T(x), U, G, M}$$

Avec;

- *x* est le nom de la variable,
- T(x) est l'ensemble des valeurs linguistiques que prendre x,
- U est l'univers du discours associé avec la valeur de base,
- G est la règle syntaxique pour générer les valeurs linguistique de *x*,
- *M* est la règle sémantique pour associe un sens à chaque valeur linguistique.

La *figure (II.7)* montre un exemple de la variable linguistique « température » avec trois termes linguistiques : Low, Medium et High. **[23]** 



**Fig.II.7 :** Exemple d'une variable linguistique « Température » avec trois termes linguistiques.

# II.2.1.8 Règles linguistiques [18]

L'idée principale des systèmes basée sur la logique floue est d'exprimer la connaissance humaine sous la forme des règles linguistiques de forme *si....alors...* Chaque règle a deux parties :

- Partie antécédente (prémisse ou condition), exprimée par si....
- Partie conséquente (conclusion), exprimée par alors....

La partie antécédente est la description de l'état de système. La partie conséquente exprime l'action que l'opérateur qui contrôle le système doit exécuter. Chaque règle floue est basée sur l'implication floue.

Il y a plusieurs formes de règle *si...alors....* La forme générale est :

Si (un ensemble des conditions est satisfait) alors (un ensemble de conséquence peut être exécute).

Zadeh a été le premier à introduire la notion de règles floues sous la forme :

Règle: Si x est A, alors y est B

# II.2.1.9 Structure générale d'un système flou

Un système flou est un système à base de connaissance particulière, dont l'architecture de base est illustrée par la *figure II.8* ci-dessous. Il se compose essentiellement de quatre modules à savoir :

- Fuzzification
- Base des règles
- Raisonnement flou
- Déffuzification



- E : représente les variables d'entrée
- U : représente les variables de sortie

Fig.II.8 : Architecture de base d'un système flou.

# II.2.1.10 Procédure de raisonnement flou

# II.2.1.10.1 Fuzzification

C'est le mécanisme réalisant l'interface « *numérique- flou (Linguistique)* » qui permet de transformer les grandeurs générées par des captures à l'entrée en partie floue défini sur un espace de représentation décrit par des ensembles flous.

# II.2.1.10.2 Base de règles floues

C'est une base de connaissance qui contient les règles floues décrivant le comportement d'un système. L'ensemble des règles se présente comme suite :

R= Si condition 1 et/ou condition 2 et/ou .... Alors action sur les sorties [18]

# II.2.1.10.3 Raisonnement flou

Il transforme à l'aide des opérateurs flous, la partie floue issue de la fuzzification en une nouvelle partie floue conformément aux règles floues et une méthode d'inférence choisie. L'agrégation des *N* règles s'effectuent en combinant les différentes règles floues par opération flou OU.

# II.2.1.10.4 Défuzzification

C'est une interface « *Linguistique- numérique* » qui transforme la partie floue issue de raisonnement flou en valeurs numérique directement exploitable par le processus.

# II.3 Systèmes et modèles flous type-2 [23]

Les systèmes flous sont constitués par des règles comme nous venons de le voir. La connaissance utilisée pour construire ces règles est de nature incertaine. Cette incertitude mène alors à obtenir des règles dont les prémisses ou les conséquences soient incertaines, ce qui provoque l'incertitude des fonctions d'appartenance. Les systèmes flous type-1 dont les fonctions d'appartenance sont des ensembles flous type-1, sont incapables de prendre en compte de telles incertitudes de règles. Une nouvelle classe de systèmes flous appelée système flou type-2 dans laquelle les valeurs d'appartenance des prémisses ou des conséquences sont elles-mêmes des ensembles flous type-1 ont été proposée. Les ensembles flous type-2 sont très efficaces dans les

circonstances où il nous est difficile de déterminer exactement les fonctions d'appartenance pour les ensembles flous ; par conséquent, ils sont très efficaces pour l'incorporation des incertitudes.

A l'heure actuelle, on considère que la sortie d'un système flou type-1 correspond à la valeur moyenne d'une densité de probabilité (pdf). Donc nous devons considérer que le calcul de la défuzzification pour un système flou de type-1 est équivalent au calcul de la moyenne d'une (pdf).

La théorie des probabilités est utilisée pour modéliser l'incertitude aléatoire, dans laquelle la fonction de distribution de probabilité (pdf) incarne la totalité des informations concernant les incertitudes aléatoires. Dans la plupart des applications pratiques, il est impossible de connaître ou de déterminer la (pdf) ainsi, nous serons obligé d'admettre le faite qu'une (pdf) sera complètement caractérisée par tous ses moments. Il n'est pas très pratique et efficace d'utiliser seulement le moment d'ordre 1, parce que les incertitudes aléatoires exigent la connaissance de la dispersion autour de la valeur moyenne, et cette information est fournie par la variance. Alors, nous devons au moins utiliser les deux premiers moments de la (pdf).

La variance nous fournie une mesure de dispersion autour de la valeur moyenne, et elle est généralement utilisée pour capturer plus d'informations concernant les incertitudes statistiques. Par conséquent, les systèmes flous ont aussi besoin d'une certaine mesure de dispersion pour leurs permettre de capturer plus d'incertitudes de règles. La logique floue de type-2 permet de prendre en charge ces mesures de dispersion.

Dans cette section, nous allons introduire la logique floue type-2, où nous essayons de présenter tous les points clefs de celle technique relativement nouvelle.

# II.3.1 Concept des ensembles flous type-2

Le concept des ensembles flous type-2 a été introduit par Zadeh [22] comme extension du concept de l'ensemble flou ordinaire appelé ensemble flou type-1. Un ensemble flou type-2 est caractérisé par une fonction d'appartenance floue, c'est à dire, la valeur d'appartenance (degré d'appartenance) de chaque élément de l'ensemble est un ensemble flou dans [0 1]. De tels ensembles, peuvent être utilisés dans les situations ou nous avons de l'incertitude dans les valeurs d'appartenance elles-mêmes. L'incertitude peut être soit dans la forme de la foncions d'appartenance ou dans l'un de ses paramètres.

Considérons la transition des ensembles ordinaires vers les ensembles flous. Lorsque nous ne pouvons pas déterminer le degré d'appartenance d'un élément à un ensemble par 0 ou 1, on utilise

les ensembles flous type-1. Similairement, lorsque nous ne pouvons pas déterminer les fonctions d'appartenance floues par des nombres réels dans [0 1], on utilise alors les ensembles flous type-2.

Donc, idéalement, nous aurons besoin d'utiliser des ensembles flous type-∞ pour compléter la représentation de l'incertitude. Bien sur, nous ne pouvons pas réaliser cela pratiquement, parce que nous devons utiliser des ensembles flous de type fini. Donc, les ensembles flous type-1 peuvent être considérés comme une approximation du premier ordre de l'incertitude, alors que les ensembles flous type-2 seront considérés comme approximation du deuxième ordre

# II.3.1.1 Exemple

Soit un ensemble flou caractérisé par une fonction d'appartenance gaussienne de moyenne *m* et de déviation standard qui prend ses valeurs dans l'intervalle  $[\sigma_1, \sigma_2]$  tel que :

$$\mu(x) = exp\left[-\frac{1}{2\left(x-\frac{m}{\sigma}\right)^2}\right]; \ \sigma \in \ [\sigma^1, \sigma^2]$$
(II.8)

A chaque valeur de  $\sigma$ , nous allons avoir une courbe d'appartenance différente (*voir FigII.9*). La valeur d'appartenance de n'importe quel x (excepté x = m) peut prendre plusieurs valeurs (dépendant de $\sigma$ ), ce qui veut dire que le degré d'appartenance n'est pas un nombre ordinaire, mais un ensemble flou. La *figure II.9* montre le domaine de l'ensemble flou associé a x = 0.65; mais ne montra pas la fonction d'appartenance associée à ce domaine



.Fig.II.9 : Ensemble flou type-2 représentant un ensemble flou type-1 avec une incertitude de variance appartenant à l'intervalle [0.135, 0.19]

# **II.3.2** Types d'ensembles flous type-2

Il existe plusieurs types d'ensemble flous types-2 :

# II.3.2.1 Ensemble type-2 Gaussien

Dans ce type d'ensembles, le degré d'appartenance de chaque point est un ensemble type-1 Gaussien dont le domaine de définition est inclus dans l'intervalle [0 1]. Notons qu'il n'est pas nécessaire que la fonction d'appartenance principale soit aussi Gaussienne.

# **II.3.2.2 Ensemble type-2 Intervalle**

Dans ce type d'ensembles, le degré d'appartenance de chaque point est un ensemble ordinaire dont le domaine de définition est inclus dans l'intervalle [0 1] **[24]**. Dans ce cas, toutes les appartenances secondaires sont égales à 1. Notant que malgré que chaque degré d'un ensemble type-2 intervalle, soit un ensemble ordinaire, l'ensemble lui-même est de type-2, parce que les degrés d'appartenance sont des ensembles et pas des nombres ordinaires.

# **II.3.2.3 Ensemble type-2 Triangulaire**

Dans ce type d'ensembles, le degré d'appartenance de chaque point est un ensemble type-1 triangulaire dont le domaine de définition est inclus dans l'intervalle [0, 1].

# II.3.3 Représentation des ensembles flous type-2

Une fonction d'appartenance type-2 eut être vue comme une fonction à deux variables. Pour chaque x et degré d'appartenance primaire  $\mu_1$ , nous avons une appartenance secondaire, qui est un nombre ordinaire noté  $\mu_2$  (*Fig.II.10*)



Fig.II.10 : a/ Représentation tridimensionnelle d'un ensemble flou type-II Gaussienb/ Degré d'appartenance flou correspondant a x = 4.25

Ainsi une fonction d'appartenance type-2 peut être représente comme suite :

$$\mu_2 \ (x, \,\mu_1) : X \times [0, \, 1] \to [0, \, 1] \tag{II.9}$$

Ou X est l'espace des entrées x. La *figure (II.10.a)* est une représentation tridimensionnelle d'un ensemble flou type-2 Gaussien, ayant une fonction d'appartenance principale Gaussienne, et la *figure (II.10.b)* représente le degré d'appartenance flou type Gaussien correspondant à x = 4.25.

# II.3.4 Opérations sur les ensembles flous type-2

Supposons que nous avons 2 ensembles flous type-1,  $A \in X$  et  $B \in X$  caractérisés par des fonctions d'appartenance  $\mu_1$ ,  $\mu_2$  tels que :

$$A = \sum_{i} \frac{\mu_{1}(x_{i})}{x_{i}}$$
(II. 10)

$$B = \sum_{i} \frac{\mu_2(x_i)}{x_i} \tag{II.11}$$

En utilisant la T-conorme max et la T-norme, les fonctions d'appartenance de l'union, l'intersection et du complément seront données par **[25]**:

$$\mu_{A\cup B}(x_i) = \max\{\mu_1(x_i), \mu_2(x_i)\} \ \forall i$$
(II. 12)

$$\mu_{A \cap B}(x_i) = \min\{\mu_1(x_i), \mu_2(x_i)\} \,\forall i$$
(II. 13)

$$\mu_{\overline{A}}(x_i) = 1 - \mu_1(x_i) \quad \forall i \tag{II. 14}$$

$$\mu_{\overline{B}}(x_i) = 1 - \mu_2(x_i) \quad \forall i \tag{II.15}$$

Puisque A et B sont des ensembles flous type-l, alors leurs valeurs d'appartenance  $\mu_1(x_i)$ , et  $\mu_2(x_i)$  sont des nombres ordinaires, par conséquent, pour chaque  $x_i$ .

Maintenant, supposons que  $\tilde{A} \in X$  et  $\tilde{B} \in X$  sont des ensembles flous type-2. Dans ce cas, les degrés d'appartenance  $\mu_1(x_i)$  et  $\mu_2(x_i)$  sont des ensembles flous type-1, donc pour calculer l'union, l'intersection et le complément de  $\tilde{A}$  et  $\tilde{B}$ , nous aurons besoin d'étendre (généraliser) les opérations min, max et l'opération de négation vers des ensembles flous. Pour cela, nous allons utiliser le fameux principe d'extension de *Zadeh*.

Soient  $\mu_{\tilde{A}}(x)$  et  $\mu_{\tilde{B}}(x)$  deux appartenances floues (ensembles flous dans  $J \subseteq [0 \ 1]$ ) dans les ensembles flous types-2  $\tilde{A}$  et  $\tilde{B}$ :

$$\mu_{\tilde{A}}(x) = \sum_{i} f_{x}(u_{i}) / u_{i}; u_{i} \in J$$
(II. 16)

$$\mu_{\tilde{B}}(x) = \sum_{i} g_{x}(w_{i}) / w_{i}; w_{i} \in J$$
(II. 17)

# **II.3.5** Opérations algébriques

Des opérations algébriques comme l'addition et la multiplication entre des ensembles flous peuvent être définis. Les deux opérations les plus intéressantes sont celles de la multiplication et de l'addition.

# **II.3.5.1** Multiplication

Le produit de deux ensembles flous  $F = \int f(v)/v \ et \ G = \int g(w)/w$  est défini par

$$F \times G = \int_{v} \int_{w} \left[ f(v)^{*} g(w) \right] / (v \times w)$$
(II.18)

où \* indique la T-norme utilisée, c.-à-d., FxG = fFG, par conséquent, T -norme produit sera utilisée pour multiplier deux ensembles flous.

# **II.3.5.2** Addition

L'addition de deux ensembles flous  $F = \int f(v)/v \ et \ G = \int g(w)/w$  est défini par

$$F+G = \int_{v} \int_{w} [f(v) * g(w)] / (v+w)$$
(II.19)

Lorsque F et G sont des ensembles type-l intervalle, l'équation (II.19) sera considérablement simplifiée à:

$$F + G = \int_{v \in F} \int_{w \in G} 1 * 1/(v + w)$$
(II.20)

Notons que chaque terme dans F+G est égal à la somme (v + w) de  $v \in F$  et  $w \in G$ , avec le plus petit terme étant  $l_f + l_a$  et le plus grand terme étant  $r_f + r_g$ . Puisque F et G sont continus, alors F + Gest aussi continu, par conséquent, F + G est un ensemble type-1 intervalle défini par le domaine  $[l_f + l_a, r_f + r_g]$  tel que :

$$F+G = \int_{v \in [l_f + l_a, r_f + r_g]} 1/v$$
 (II.21)

D'une manière similaire, la somme de *n* ensembles type-1 intervalle  $F_{1},...,F_{n}$ , ayant comme domaine  $[l_{1}, r_{1}] \ldots [l_{n}, r_{n}]$ , respectivement, est un ensemble intervalle sur le domaine  $[\sum_{i=1}^{n} l_{i} \sum_{i=1}^{n} r_{i}]$ 

# II.3.6 Système flou type-2

La structure d'un système flou type-2 est représentée dans la *figure (II.11)* **[26]**.Nous allons supposer dans cette section que les fonctions d'appartenance des prémisses et des conséquences sont de type-2, malgré que cela n'est pas pratiquement nécessaire, car un système flou reste toujours de type-2 même s'il contient quelques fonctions d'appartenance de type-1



Fig.II.11 : Structure d'un système flou type-2, avec ses deux sorties

# **II.3.6.1 Fuzzification**

Dans cette étape seule la fuzzification singleton sera utilisée [25], en d'autres termes, l'entrée floue est un point singulier possédant une valeur d'appartenance unitaire.

# II.3.6.2 Règle

Dans cette étape la différence entre le type-1 et le type-2 réside seulement dans la nature des fonctions d'appartenance, donc, la structure des règles dans le cas de type-2 va rester exactement la même, la seule différence étant que quelque (ou toutes) les fonctions d'appartenance seront de type-2 ; alors la  $I^{eme}$  règle d'un système flou type-2 aura la forme [27].

R = Si condition 1 et/ou condition 2 et/ou.....et/ou condition *n*, *Alors* Action à la sortie

Il n'est pas nécessaire que toutes les fonctions d'appartenance des prémisses et des conséquences soient de type-2. Il suffit qu'une seule fonction d'appartenance dans une prémisse ou dans une conséquence soit de type-2 pour que tout le système soit de type-2.

# II.3.6.3 Réduction de type

Remarquons dans la *figure (II.12)* que le bloc de déffuzification dans le système flou type-1 a été remplacé par deux blocs : bloc de réduction de type et bloc de déffuzification.



Fig.II.12: Discrétisation d'un ensemble flou type-2 pour des raisons de réduction de type

Dans un système flou type-1, ou les ensembles de sortie sont des ensembles flous type-1, nous effectuons la défiizzification en but d'obtenir un nombre (ensemble type-0) représentant la combinaison des ensembles de sortie.

Dans le cas du type-2, les ensembles de sortie sont de type-2, donc nous devons utiliser des versions étendues (en utilisant le principe d'extension) des méthodes de défuzzification type-1. Puisque la défuzzification type-1 nous donne un nombre ordinaire à la sortie du système flou, l'opération de défuzzification étendue dans le cas du type-2 nous donne un ensemble flou de type-1 à la sortie. Cette opération de transformation d'un ensemble flou type-2 à un ensemble flou type-1, est l'appellée alors "Réduction de type" **[24]**, et on appelle l'ensemble flou type-1 obtenu "Ensemble de type réduit". L'ensemble flou de type réduit doit ensuite être défuzzifié pour obtenir un nombre ordinaire.

# **II.3.6.4 Déffuzification**

Pour obtenir une sortie ordinaire du système flou type-2, nous devons déffuzifier l'ensemble de type réduit.

# **II.4** Conclusion

En fait le développement de la logique floue va beaucoup plus loin que les quelques définitions et propriétés présentés précédemment dans ce chapitre, son application dans plusieurs disciplines de l'ingénierie a joué un rôle important dans son développement.

L'insuffisance des résultats obtenus en appliquant les techniques de la logique floue type -1 dans certaines disciplines telles que l'étude des systèmes complexes et multi variables ont conduit les chercheurs à introduire de nouvelles propriétés et techniques de calcule telle que l'introduction des fonctions d'appartenance floues dans un système flou, c'est dans ce dernier concept que réside la déférence entre les techniques appliquées avant et celles appliquer après l'introduction de cette idée, ce qui a amener a créé ce qu'on appel la logique floue Type -2

Cette deuxième partie de ce chapitre a été ainsi dédiée a l'introduction de la logique floue type-2, ou nous avons présenté son fondement théorique ainsi que ses notions de base. Parmi les points que nous avons traité nous citons, concepts des ensembles flous type-2, représentation des ensembles flous type -2, opération sur les ensembles flous type-2, systèmes flous type-2, et enfin la réduction de type et l'interprétation des ensembles type réduits, mais le développement de cette discipline ne se limite pas aux simples définitions que nous avons abordé dans ce chapitre.

# <u>Chapitre III</u>: Seuillage flou.

# **III.1 Introduction**

L'incertitude et l'imprécision des données peuvent être présentes à tous les niveaux d'un système de traitement, d'analyse et d'interprétation d'image. Ce genre d'information incomplète peut être présenté soit au niveau de l'image bidimensionnelle formée à partir de la projection d'une scène réelle à trois dimensions, soit au niveau de la précision et de la manipulation des instruments qui sont toujours sujets à des erreurs.

Avoir un modèle mathématique qui sache appréhender ce genre d'information incertaine et imprécise à un niveau quelconque d'un système de vision, qui puisse contrôler sa propagation et pouvoir en tirer profit aux niveaux suivants peut être alors intéressant. C'est ainsi plusieurs auteurs ont essayé de créer les moyens nécessaires à l'application de la logique floue en analyse d'images. Une discussion a propos de l'état de l'art des méthodologies et de certains des algorithmes qui utilisent la logique floue dans le domaine du seuillage sera présentée dans ce chapitre.

# III.2 Indices de flou d'une image [28]

En logique floue, un élément peut appartenir à plusieurs classes en même temps avec des degrés différents.

Soit une image X de dimension  $M \times N$ , représentée sur  $N_G$  niveau de gris, notée :

$$X \equiv \mu_X (x_{mn}) \equiv \sum_{m \in M} \sum_{n \in N} \mu_{mn} / x_{mn}$$
(III. 1)

où  $\mu_x(x_{mn}) \in [0,1]$  représente le degré de brillance du pixel (m, n) d'intensité  $x_{mn}$ .

Pour évaluer l'ambigüité associée aux niveaux de gris présents dans l'image X, par la valeur d'un indice de flou, plusieurs mesures existent. Ces mesures prennent en compte la distance entre l'ensemble X et l'ensemble ordinaire  $\tilde{X}$  le plus proche.

Cet ensemble ordinaire est donné sous cette forme :

$$\mu_{\tilde{X}}(x_{mn}) = \begin{cases} 1 & si \ \mu_X(x_{mn}) \ge 0.5\\ 0 & si \ \mu_X(x_{mn}) < 0.5 \end{cases}$$
(III. 2)

# III.2.1 Indice de flou

L'indice de flou d'un ensemble A ayant n points est défini comme suit :

$$\gamma(A) = \frac{2}{n^k} d(A, \tilde{A})$$
(III.3)

avec  $d(A, \tilde{A})$ , la distance entre A et le sous ensemble ordinaire  $\tilde{A}$  le plus proche.  $\tilde{A}$  est donné par l'équation (*III*. 2) et k est une constante positive de normalisation dont la valeur dépend du type de la distance utilisée.

# III.2.2 Distance de Hamming ou linéaire

La distance de Hamming ou linéaire entre deux ensembles flous  $A_1$  et  $A_2$  sur X est définie par :

$$d_{l}(A_{1}, A_{2}) = \sum_{x \in X} |A_{1}(x) - A_{2}(x)|$$
(III. 4)

### III.2.3 Distance euclidienne ou quadratique

La distance quadratique entre deux ensembles flous  $A_1$  et  $A_2$  sur X est définie par :

$$d_q (A_1, A_2) = \left[\sum_{x \in X} (A_1(x) - A_2(x))^2\right]^{\frac{1}{2}}$$
(III.5)

Plusieurs indices de flou ont été développés selon plusieurs distances existantes. La distance Euclidienne équivaut à utiliser k = 0.5 dans l'équation (III.3) et la distance de *Hamming* équivaut à utiliser k=1. Les indices de flou d'un ensemble A correspondant à ces distances sont :

$$\gamma_{l}(A) = \frac{2}{n} d_{1}(A, \tilde{A})$$

$$= \frac{2}{n} \sum_{x \in X} |\mu_{A}(x) - \mu_{\tilde{A}}(x)| \qquad \text{(III.6)}$$

$$= \frac{2}{n} \sum_{x \in X} \mu_{A \cap \tilde{A}}(x)$$

$$\gamma_{q}(A) = \frac{2}{n^{\frac{1}{2}}} d_{q}(A, \tilde{A})$$

$$= \frac{2}{n^{1/2}} [\sum_{x \in X} (\mu_{A}(x) - \mu_{\tilde{A}}(x))^{2}]^{\frac{1}{2}} \qquad \text{(III.7)}$$

Pour évaluer l'ambiguïté associée à un ensemble flou, il est aussi possible d'utiliser la mesure d'information classique d'entropie adaptée au cas flou. L'incertitude de la nature floue dans un ensemble flou *A* peut être mesurée par : **[30]** 

$$HF(A) = \frac{1}{n \ln 2} \sum_{x \in A} S(\mu_A(x))$$
$$= -\frac{1}{n \ln 2} \sum_{x \in A} \left[ \mu_A(x) \ln \mu_A(x) + \left(1 - \mu_A(x)\right) \ln \left(1 - \mu_A(x)\right) \right] \quad \text{(III.8)}$$

où S est appelée la fonction de Shannon

Dans le cas d'une image X de dimension  $M \times N$ , ces fonctions se traduisent par :

$$\gamma_l(X) = \frac{2}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \mu_{X \cap \tilde{X}}(x_{ij}) = \frac{2}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} |\mu_X(x_{ij}) - \mu_{\tilde{X}}(x_{ij})|$$
(III.9)

$$\gamma_q(X) = \frac{2}{(MN)^{1/2}} \left[ \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \left( \mu_X(x_{ij}) - \mu_{\tilde{X}}(x_{ij}) \right)^2 \right]^{\frac{1}{2}}$$
(III. 10)

$$HF(X) = \frac{1}{MN \ln 2} \left[ \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} S(\mu_X(x_{ij})) \right]$$
(III.11)

Soit f la fonction associée à chaque niveau de gris g  $(0 \le i \le N_G - 1)$ , le nombre d'occurrence h(g) du niveau g, les mesures floues (III.9), (III.10) et (III.11) peuvent alors s'écrire comme suit :

$$\gamma_l(X) = \frac{2}{MN} \sum_{g=0}^{N_G - 1} \left[ \mu_{X \cap \tilde{X}}(g) \cdot h(g) \right] = \frac{2}{MN} \sum_{g=0}^{N_G - 1} \left| \mu_X(g) - \mu_{\tilde{X}}(g) \right| \cdot h(g) \quad (\text{III. 12})$$

$$\gamma_q(X) = \frac{2}{(MN)^{1/2}} \left[ \sum_{g=0}^{N_G - 1} (\mu_X(g) - \mu_{\tilde{X}}(g))^2 \cdot h(g) \right]^{1/2}$$
(III.13)

$$HF(X) = \frac{1}{MN \ln 2} \sum_{g=0}^{N_G-1} \left[ S\left(\mu_X(g)\right) \cdot h(g) \right]$$
(III.14)

Dans les techniques de segmentation par seuillage, l'objectif est de déterminer le meilleur seuil permettant d'extraire les objets de l'image. En raisonnant avec la logique floue le but est de trouver la valeur seuil qui minimise l'incertitude associés à une image, cette incertitude peut être déterminée par l'un des indices de flou présentés ci-dessus . Notons qu'en pratique l'équation (*III.14*) est la plus utilisée.

Dans la suite de ce travail, nous allons étudier avec plus de détails certaines techniques de seuillage qui adoptent le concept de la logique floue. Nous allons voire aussi d'autres techniques qui introduisent la mesure d'entropie en association avec le flou.

### III.3 Degré d'appartenance

Pour effectuer un seuillage flou il faut évidemment définir le degré d'appartenance d'un niveau de gris à la classe fond b (background) ou objet f (forward). Celui-ci peut être définit de plusieurs manières. La formule qui revienne le plus souvent dans la littérature **[31]** est (*Fig III.1*)

$$\mu_{b}(g) = \begin{cases} 1 & si \ g \leq a \\ 1 - \frac{(g-a)^{2}}{(c-a)(b-a)} & si \ a \leq g \leq b \\ \frac{(g-c)^{2}}{(c-a)(c-b)} & si \ b < g \leq c \\ 0 & si \ g \geq c \end{cases}$$
(III. 15)
$$\mu_{f}(g) = \begin{cases} 0 & si \ g \le a \\ \frac{(g-a)^{2}}{(c-a)(b-a)} & si \ a < g \le b \\ 1 - \frac{(g-c)^{2}}{(c-a)(c-b)} & si \ b < g \le c \\ 1 & si \ g > c \end{cases}$$
(III. 16)

avec bien sure,

$$\mu_b(g) + \mu_f(g) = 1$$



Fig.III.1 : Courbe des degrés d'appartenance.

Le seuil *s* est généralement compris entre *a* et *c* et correspond a la valeur de *g* qui vérifie  $\mu_b(g) = \mu_f(g) = 0.5.$ 

Certaines méthodes de seuillage cherchent alors, comme nous le verrons, les valeurs de a, b et c pour déduire en suite le seuil s

Cheng et al. [32] utilisent la fonction suivante (Fig III.2)

$$\mu_{b}(g) = \begin{cases} 0 & si \ g \le a \\ \frac{g-a}{c-a} & si \ a < g < c \\ 1 & si \ c \le g \end{cases}$$
(III.17)



Fig.III.2 : Courbe des degrés d'appartenance.

Le point de croisement *b* qui correspond à  $\mu_b(g) = \mu_f(g)$ , donne le seuil  $s = b = \frac{c+a}{2}$ . Le problème revient alors à déterminer les valeurs *a* et *c* afin de pouvoir déduire *s*.

Les degrés d'appartenance d'un niveau de gris aux classes fond et objet peuvent être également définis à partir de fonction  $S_z$  de Zadeh. Cette fonction est définie de manière que, pour tout élément g dans un intervalle [a, b] inclus dans [0,  $N_G$ ], la valeur de  $S_z$  soit dans l'intervalle [0, 1]

$$S_{z}(g) = \begin{cases} 0 & \text{si } g \leq a \\ 2\left[\frac{g-a}{c-a}\right]^{2} & \text{si } a \leq g \leq b \\ 1-\left[\frac{g-c}{c-a}\right]^{2} & \text{si } b \leq g \leq c \\ 1 & \text{si } g \geq c \end{cases}$$
(III. 19)

Le point b = (c+a)/2, pour lequel  $S_z$  possède la valeur 0.5 est appelé point de croisement et la valeur de (c-a) est dite largeur de bande. En notant par *s* le point de croisement et en posant |c - a| = 2k pour la largeur de bande, la fonction de *Zadeh*  $S_z$  peut alors s'écrire en fonction du paramètre *k* (*voir Fig III.3*) comme suit :

$$S_{z}(g) = \begin{cases} 0 & si \ g \le s - k \\ \left[\frac{g - (s - k)}{2k^{2}}\right]^{2} & si \ s - k \le g \le s \\ 1 - S_{z}(2s - g) & si \ s \le g \le s + k \\ 1 & si \ g \ge s + k \end{cases}$$
(III. 20)

**Fig III.3:** Fonction S<sub>z</sub> de Zadeh

Les degrés d'appartenance de tous les niveaux de gris aux deux classes : fond et objet sont :

$$\mu_{b}(g) = \begin{cases} 0 & si \, g < s - k \\ S_{z}(s,g) & si \, s - k \le g \le s + k \\ 1 & si \, g > s + k \end{cases}$$
(III.21)

$$\mu_{f}(g) = \begin{cases} 1 & si \ g < s - k \\ 1 - S_{z}(s, g) & si \ s - k \le g \le s + k \\ 0 & si \ g > s + k \end{cases}$$
(III.22)

Le seuil *s* correspondant a  $\mu_b(g) = \mu_f(g) = 0.5$  est situé entre s - k et s + k. Le choix de *k* est primordial, si l'intervalle [*s*-*k*, *s*+*k*] est trop petit, il est possible que des seuils non représentatifs soient détectés, par contre si cet intervalle est trop grand, des bons seuils

peuvent être éliminés. On peut alors procéder a son calcul comme pour les paramètres *a*, *b* et *c* précédents puis déduire le seuil *s* ou le fixer puis déterminer la valeur du seuil *s*.

Une autre manière de déterminer le degré d'appartenance d'un niveau de gris a été proposée par *Huang* et *Wang* **[33]**.

$$\mu_{f}(g) = \begin{cases} \frac{1}{1 + \frac{|g - m_{1}(s)|}{D}} & \text{si } g \leq s \\ \frac{1}{1 + \frac{|g - m_{2}(s)|}{D}} & \text{si } g > s \end{cases}$$
(III.23)

avec

$$m_1(s) = \frac{\sum_{g=0}^{s} g.h(g)}{\sum_{g=0}^{s} h(g)} \qquad m_2(s) = \frac{\sum_{g=s+1}^{N_G-1} g.h(g)}{\sum_{g=s+1}^{N_G-1} h(g)}$$
(III.24)

et

$$D = g_{max} - g_{min} = N_G - 1 \qquad si \qquad g_{max} = N_G - 1 \qquad \text{et} \qquad g_{min} = 0$$

Dans [31] et [34] les degrés d'appartenance d'un niveau de gris g est :

$$\mu(g) = \begin{cases} e^{-c|g-m_1|} & \text{si } g \le s \\ e^{-c|g-m_2|} & \text{si } g > s \end{cases}$$
(III.25)

avec

$$m_1$$
 et  $m_2$  définies en(III.24),

et

*c* est une constante de normalisation telle que  $c = \frac{1}{g_{max} - g_{min}}$ 

 $g_{max}$  et  $g_{min}$  sont respectivement les niveaux de gris max et min.

#### **III.4** L'utilisation des indices de flou

Soit une image X ayant un histogramme des niveaux de gris bimodal, le point de croisement s choisi comme seuil optimal séparant l'image en deux classes est celui pour lequel l'ambiguïté est maximale, c'est-à-dire S(g) = 0.5. Les différents niveaux de gris seront

séparés en deux classes :  $g \in [0, s - 1]$  où S(g) < 0.5 et  $g \in [s + 1, N_G - 1]$  où S(g) > 0.5.

La valeur de *s* pour laquelle l'intervalle [s - k, s + k] possède un nombre minimum d'éléments g ayant  $\mu_f(g) \approx 0.5$  et un nombre maximum d'éléments ayant  $\mu_f(g) \approx 0$  ou 1 correspond à une vallée dans l'histogramme. Le pic, à son tour, est représenté par la valeur de *s* qui possède un nombre maximum d'éléments g ayant  $\mu_f(g) \approx 0.5$  et un nombre minimum d'éléments ayant  $\mu_f(g) \approx 0$  ou 1. L'utilisation des indices de flou peut ne pas donner des bons résultats lorsque les images traitées ne possèdent pas des seuils représentatifs dans les vallées de l'histogramme.

#### III.4.1 Méthode de Chaira et Ray

Les degrés d'appartenance de chaque niveau de gris présent dans une image permettent aux indices de flou  $\gamma_l$  et  $\gamma_q$  donnés respectivement par les équations (III.12) et (III.13) d'être utilisés dans le but de mesurer l'ambiguïté associée à l'image. A chaque valeur de croisement possible correspond une partition floue de l'image.

Ainsi, dans [34]  $\gamma_l$  et  $\gamma_q$  prennent les formes suivantes :

$$\gamma_l = \frac{2}{MN} \sum_{g=0}^{N_G - 1} \min(\mu(g), 1 - \mu(g))$$
(III.26)

$$\gamma_q = \frac{2}{\sqrt{MN}} \sum_{g=0}^{N_G - 1} \min(\mu(g), 1 - \mu(g))$$
(III.27)

avec  $\mu(g)$  définie par l'équation (III.25)

#### III.4.2 Méthode de seuillage de Huang et Wang

*Huang* et *Wang* ont proposé un indice de flou qui mesure la distance entre l'image en niveaux de gris et sa version binaire. [33]

Dans ce schéma, l'ensemble de l'image est représentée comme un tableau à deux dimensions :

$$X = \left\{ I(i,j), \mu_f[I(i,j)] \right\}$$
(III.28)

ou :

 $0 \le \mu_f[I(i,j)] \le 1$ 

 $\mu_f[I(i, j)]$  représente pour chaque pixel de coordonnés (i, j) sa mesure de flou d'appartenance à l'objet.

Étant donné la valeur de degrés d'appartenance floue pour chaque pixel, un indice flou pour l'image entière peut être obtenu par l'entropie de *Shannon* ou la mesure de *Yagers* [49]. Le seuil optimal est déterminé par la minimisation de l'indice de flou définit en termes de moyenne des classes (objet, fond)  $m_f(s)$ ,  $m_b(s)$  et les fonctions d'appartenances  $\mu_f[I(i,j)]$ ,  $\mu_b[I(i,j)]$ .

Le degré d'appartenance du pixel de coordonnées (i, j) ayant un niveau de gris I(i, j) = g à la classe objet est données par l'équation (III.23), (III.24)

Le seuil optimal sopt est celui qui minimise le critère suivant :

$$J(T) = \frac{1}{MNln2} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} S\left(\mu(I(i,j))\right)$$
(III.29)

Dans notre cas la formule (111.29) devient :

$$J(T) = \frac{1}{MNln2} \sum_{i=0}^{N_G - 1} h(g) . S\left(\left(\mu_f(g)\right)\right)$$
(III.30)

Avec S la fonction de Shannon telle que :

$$S(\mu) = -\mu . \log \mu - (1 - \mu) . \log(1 - \mu)$$

De l'équation (III. 29) on déduit que le critère à minimiser est de la forme suivante :

$$-\frac{1}{MN \log 2} \sum_{g=0}^{N_G-1} ([\mu_f(g,T) \log(\mu_f(g,T))] + [1 - \mu_f(g,T)] \log[1 - \mu_f(g,T)])h(g) \quad (\text{III.31})$$

#### III.4.3 La méthode de seuillage de Pal

*Pal* et *Rosenfeld* **[46]** ont utilisé le concept de la géométrie flou pour déterminer le seuil optimal en maximisant la compacité floue définie comme suit :

$$s_{opt} = \arg \max \left\{ compacité \left[ \mu(s) \right] = \frac{Surf \left[ \mu(s) \right]}{Perim \left[ \mu(s) \right]^2} \right\}$$
(III.32)

où Surf représente la Surface telle que :

Surf 
$$(\mu(s)) = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} \mu[I(i,j)]$$
 (III.33)

et Perm est le Périmètre défini comme :

$$Perim (\mu(T)) = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} |\mu [I(i,j)] - \mu [I(i,j+1)]| + \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} |\mu [I(i,j)] - \mu [I(i+1,j)]$$
(III. 34)

En pratique, on peut utiliser la fonction standard *S* définie dans (*III.20*) pour assigner la fonction d'appartenance au pixel de coordonnées  $(i, j) : \mu$  (i, j) = S [*I* (i, j) ; a, b, c]. Rappelons que *b* représente le point de croisement tel que  $b = \frac{a+c}{2}$  et  $\Delta b = b - a = c - b$  est la largeur de bande. En faisant varier *s* entre *b* et  $\Delta b$ , on peut déterminer pour chaque pixel  $\mu$  (*I*(*i*, *j*)). *b* et  $\Delta b$  sont connus à priori.

On retrouve la même méthode dans [34] ou  $\mu$  (*I* (*i*, *j*)) est déterminé par la formule de l'équation (*III.25*)

#### **III.5** Méthode basée sur l'algorithme FCM

L'algorithme de classification floue FCM "Fuzzy-C Means" [43][44] est populaire dans le domaine de la classification ou de la segmentation. Il a été aussi utilisé comme modèle dans le seuillage.

Soient  $X = \{x_1, x_2, ..., x_N\}$  un ensemble fini de *N* objets à regrouper en *K* classes et soit  $U = \mu_{ik}$  une partition floue de *X* en *K* classes, où  $\mu_{ik}$  est le degré d'appartenance de l'objet  $x_i$ à la classe *K*, sous la contrainte  $\sum_{k=1}^{K} \mu_{ik} = 1 \quad \forall i$ .

L'algorithme FCM a pour but de déterminer les centres des classes  $m_k$  et la matrice Uqui minimisent le critère quadratique  $J_m$  défini par:

$$J_m(U,v) = \sum_{i=1}^N \sum_{k=1}^K (\mu_{ik})^{\tau} (d_{ik})^2$$
(III.35)

où  $\tau$  est le facteur de flou (1 <  $\tau$  <  $\infty$ ),  $d_{ik}$  est une distance entre l'objet  $x_i$  et le centre  $m_k$  d'une classe.

La minimisation de ce critère aboutit aux expressions suivantes :

Degré d'appartenance :

$$\mu_{ik} = \frac{1}{\sum_{j=1}^{K} \left(\frac{d_{ik}}{d_{ij}}\right)^{\frac{2}{\tau-1}}}$$
(III.36)

avec:  $1 \le i \le N$ ,  $1 \le k \le K$ 

Centre de la classe :

$$m_{k} = \frac{\sum_{i=1}^{N} \mu_{ik}^{\tau} x_{i}}{\sum_{i=1}^{N} \mu_{ik}^{\tau}}$$
(III. 37)

avec :  $1 \le k \le K$ 

Dans le cas du seuillage, on considère les pixels comme des objets et le nombre de classes K est égal à 2 (objet et fond).

Les centres des classes prennent la forme suivante :

$$m_{k} = \frac{\sum_{g=0}^{N_{G}-1} \mu_{k}^{\tau}(g).g.h(g)}{\sum_{g=0}^{N_{G}-1} \mu_{k}^{\tau}(g).h(g)}$$
(III.38)

avec k = f ou b, f: pour l'objet, et b: pour le fond,  $\mu_k(g)$  est le degré d'appartenance du niveau de gris g à la classe k.

Plusieurs méthodes de seuillage basées sur l'algorithme FCM ont été proposées. Parmi elles, on peut citer la méthode de *Jawahar* et *al*.

#### III.5.1 Méthode Jawahar et al

Cette méthode consiste à chercher le seuil optimal  $s_{opt}$  comme étant le niveau de gris qui égalise le degré d'appartenance à la classe objet à celui de classe fond, c'est-à-dire au point de croisement des degrés d'appartenance [36][47].

$$s_{opt} = \arg_g equal \left[ \mu_f^{\tau}(g) = \mu_b^{\tau}(g) \right]$$
(III.39)

où

$$\mu_f^{\tau}(g) = \frac{1}{1 + \left(\frac{d(g, m_f)}{d(g, m_b)}\right)^{2/\tau - 1}}, \ \mu_b^{\tau}(g) = 1 - \mu_f^{\tau}(g)$$
(III.40)

avec

$$d(g, m_k) = (g - m_k)^2, \quad k = b, f$$
 (III.41)

 $d(g, m_k)$  est la fonction de distance euclidienne entre le niveau de gris g et la moyenne de la classe objet ou fond  $m_k$ , alors que  $\tau$  est l'indice de fuzzification flou, lorsque  $\tau = 1$  on obtient la classification par *K*-means.

Les centres de ces classes sont calculés comme suit :

$$m_{k} = \frac{\sum_{g=0}^{N_{G}-1} g. P(g) \mu_{k}^{\tau}(g)}{\sum_{g=0}^{N_{G}-1} P(g) \mu_{k}^{\tau}(g)}; k = f, b$$
(III.42)

le critère d'arrêt et donnes par :  $/m_b^{t+1} - m_b^t / + /m_f^{t+1} - m_f^t / \le \varepsilon$ 

Une autre variante proposée par *Jawahar* et *al* consiste à modifier la fonction de distance par une distance gaussienne et le degré d'appartenance de la manière suivante : **[36]** 

$$d(g, m_k) = \frac{1}{2} \left(\frac{g - m_k}{\sigma_k}\right)^2 + \log \sigma_k - \log \beta_k \tag{III.43}$$

où  $m_k$  est indiqué dans l'expression (III.38).

$$\beta_k = \frac{\sum_{g=0}^{N_G - 1} P(g) \mu_k^{\tau}(g)}{\sum_{g=0}^{N_G - 1} P(g) [\mu_f^{\tau}(g) + \mu_b^{\tau}(g)]}$$
(III.44)

et

$$\sigma_k^2 = \frac{\sum_{g=0}^{N_G - 1} P(g) \mu_k^{\tau}(g) (g - m_k)^2}{\sum_{g=0}^{N_G - 1} \mu_k^{\tau}(g) P(g)}$$
(III.45)

#### III.6 Seuillage basée sur l'entropie floue

Pour séparer les niveaux de gris en deux classes il faut trouver un seuil *s* qui partage l'histogramme de ces niveaux de façon à retenir un maximum d'information.

Si on veut tenir compte de l'information ambigüe fournie par les niveaux proche de la frontière séparatrice des deux classes, il est intéressant d'utiliser la mesure d'information définie par l'entropie floue [40] donnée par l'équation (*III.8*).

Pour mesurer le degré de flou associé à une image seuillée, l'utilisation des deux distributions de nature floue suivante est proposée [41]:

$$D_f: \ \mu_f(0), \ \mu_f(0), \ \dots, \ \mu_f(N_G - 1)$$
(III.46)

$$D_b: \mu_b(0), \mu_b(0), \dots, \mu_b(N_G - 1)$$
 (III.47)

On considère que pour chaque seuil *s* possible, il y a un intervalle [s - k, s + k] ou l'information est ambigüe, *k* peut être fixé a priori. En éliminant la partie constante de (*III.14*), cette équation devient :

$$HF(s) = -\sum_{g=0}^{N_G-1} p_g \left[ \mu_f(g) \ln\left(\mu_f(g)\right) + (1 - \mu_f(g)) \log(1 - \mu_f(g)) \right]$$
(III.48)

où  $\mu_f(g)$  peut être donné par (III.22). Comme en dehors de [s - k, s + k] il n'y a pas d'incertitude,  $ln(\mu_f(g)) = 0 \forall g \in [0, s - k]$  et  $\mu_f(g) = 0 \forall g \in [s + k, n - 1]$ . L'équation (III.48) devient alors :

$$HF(s) = -\sum_{g=s-k+1}^{s+k-1} p_g \left[ \mu_f(g) \ln \left( \mu_f(g) \right) + (1 - \mu_f(g)) \ln (1 - \mu_f(g)) \right]$$
(III.49)

La minimisation de l'entropie floue HF(s) permet de trouver le seuil optimal s

#### III.6.1 Méthode de Chang et al.

Dans cette méthode, les degrés d'appartenance  $\mu_b(g)$  et  $\mu_f(g)$  sont données par les équations (III.17) et (III.18). Les valeurs des paramètres a et c sont déterminés en maximalisant l'entropie suivante :

$$H(a,c) = P_b \log P_b - P_f \log P_f$$
(III.50)

avec

$$P_b = \sum_{g=0}^{N_G - 1} \mu_b(g) \frac{h(g)}{N}$$
(III.51)

$$P_f = \sum_{g=0}^{N_G - 1} \mu_f(g) \frac{h(g)}{N}$$
(III.52)

Les valeurs optimales de  $a_{op}$  et  $c_{op}$  sont alors utilisées pour le calcul du seuil  $s = \frac{a_{op} + c_{op}}{2}$ .

Le calcul de  $a_{op}$  et  $c_{op}$  peut se faire d'une manière exhaustive ou par l'intermédiaire du recuite simulé [32].

#### III.6.2 Méthode de Tao et al.

Dans cette méthode, les degrés d'appartenance  $\mu_b(g)$  et  $\mu_f(g)$  sont décrites dans les formules (III.21) et (III.22), nécessitent la connaissance des paramètres *a*, *b* et *c*. Ceux-ci peuvent être déterminés en maximalisant l'entropie suivante :

$$H(a,b,c) = H_b + H_f \tag{III.53}$$

où

$$H_{b} = -\sum_{g=0}^{N_{G}-1} \frac{h(g)\,\mu_{b}(g)}{N\,P_{b}} \log\left(\frac{h(g)\,\mu_{b}(g)}{N\,P_{b}}\right)$$
(III.54)

$$H_{f} = -\sum_{g=0}^{N_{G}-1} \frac{h(g)\,\mu_{f}(g)}{N\,P_{f}} \log\left(\frac{h(g)\,\mu_{f}(g)}{N\,P_{f}}\right)$$
(III.55)

avec

$$P_b = \sum_{g=0}^{N_G - 1} \frac{h(g)}{N} \mu_b(g)$$
(III.56)

$$P_f = \sum_{g=0}^{N_G - 1} \frac{h(g)}{N} \mu_f(g)$$
(III.57)

Le calcul de  $a_{op}$ ,  $b_{op}$ , et  $c_{op}$  qui maximise H(a, b, c) peut se faire également d'une manière exhaustive ou en faisant appel aux méthodes méta-heuristiques telle que les Algorithmes génétiques [37] ou les colonies de fourmis [38].

Le seuil optimal est ensuite déterminé en résolvant l'équation suivante :

$$\mu_b(s) = \mu_f(s) = 0.5$$

La solution est :

$$s = \begin{cases} a_{op} + \sqrt{\frac{(c_{op} - a_{op})(b_{op} - a_{op})}{2}} & si \ \frac{a_{op} + c_{op}}{2} \le b_{op} \le c_{op} \\ c_{op} - \sqrt{\frac{(c_{op} - a_{op})(c_{op} - b_{op})}{2}} & si \ a_{op} \le b_{op} \le \frac{a_{op} + c_{op}}{2} \end{cases}$$
(III.58)

#### III.6.3 Méthode de Lin et al.

La valeur du seuil est déterminée en maximisant l'entropie floue suivante : [39]

$$H(s) = -\sum_{g=0}^{N_G-1} \frac{h(g)}{\mu_b(g) P_b} \log\left(\frac{h(g)}{\mu_b(g) P_b}\right) - \sum_{g=0}^{N_G-1} \frac{h(g)}{\mu_f(g) P_f} \log\left(\frac{h(g)}{\mu_f(g) P_f}\right) \quad (III.59)$$

avec

$$P_b = \sum_{g=0}^{N_G - 1} \frac{h(g)}{\mu_b(g)}$$
(III.60)

$$P_f = \sum_{g=0}^{N_G - 1} \frac{h(g)}{\mu_f(g)}$$
(III.61)

Les degrés d'appartenance  $\mu_b(g)$  et  $\mu_f(g)$  sont calculés comme dans *Huang* et *Wang*.

#### III.6.4 Méthode de Braviano

Cette autre méthode consiste à utiliser deux variantes de l'entropie floue, mais en considérant la totalité de la dynamique, même en dehors de l'intervalle d'incertitude **[28]**.

#### a/ Variante 1

Les distributions des degrés d'appartenance normalisées par rapport à la classe (objet ou fond) sont définies comme suit :

$$D_f: \frac{\mu_f(0)}{P_f}, \frac{\mu_f(1)}{P_f}, \dots, \frac{\mu_f(N_G - 1)}{P_f}$$
(III.62)

$$D_b: \frac{\mu_b(0)}{P_b}, \frac{\mu_b(1)}{P_b}, \dots, \frac{\mu_b(N_G - 1)}{P_b}$$
(III.63)

où  $P_f = \sum_{i=0}^{s+k} \mu_f(i)$  et  $P_b = \sum_{i=s-k}^{N_G-1} \mu_b(i)$  ont la même fonction que  $P_s$  défini dans la section (1.1.4.11)

La valeur de seuil s est celle qui minimise l'incertitude

$$HF(X) = \frac{1}{M.N.\ln 2} \sum_{i=0}^{N_G-1} S(\mu_x(g))h(i)$$
(III.64)

Sachant que

$$S(\mu_x(g)) = \mu(g)log\mu(g) - (1 - \mu(g))log(1 - \mu(g))$$
(III.65)

et négligeant le terme ln2, HF(X) devient :

$$HF(X \setminus s, k) = HF(b \setminus s, k) + HF(f \setminus s, k)$$

$$= -\sum_{i=0}^{s+k} p_i \left[ \frac{\mu_f(i)}{P_f} \ln\left(\frac{\mu_f(i)}{P_f}\right) + \left(1 - \frac{\mu_f(i)}{P_f}\right) \ln\left(1 - \frac{\mu_f(i)}{P_f}\right) \right] \\ - \sum_{i=s-k}^{N_G - 1} p_i \left[ \frac{\mu_b(i)}{P_b} \ln\left(\frac{\mu_b(i)}{P_b}\right) + \left(1 - \frac{\mu_b(i)}{P_b}\right) \ln\left(1 - \frac{\mu_b(i)}{P_b}\right) \right]$$

. . .

$$= -\left[\frac{1}{P_{f}}\ln\left(\frac{1}{P_{f}}\right) + \left(1 - \frac{1}{P_{f}}\right)\ln\left(1 - \frac{1}{P_{f}}\right)\right] \cdot \sum_{i=0}^{S+k} p_{i} \left[\frac{\mu_{f}(i)}{P_{f}}\ln\left(\frac{\mu_{f}(i)}{P_{f}}\right) + \left(1 - \frac{\mu_{f}(i)}{P_{f}}\right)\ln\left(1 - \frac{\mu_{f}(i)}{P_{f}}\right)\right] \\ - \sum_{i=s-k}^{S+k} p_{i} \left[\frac{\mu_{b}(i)}{P_{b}}\ln\left(\frac{\mu_{b}(i)}{P_{b}}\right) + \left(1 - \frac{\mu_{b}(i)}{P_{b}}\right)\ln\left(1 - \frac{\mu_{b}(i)}{P_{b}}\right)\right] \\ - \left[\frac{1}{P_{b}}\ln\left(\frac{1}{P_{b}}\right) + \left(1 - \frac{1}{P_{b}}\right)\ln\left(1 - \frac{1}{P_{b}}\right)\right] \cdot \sum_{i=s-k}^{N_{G}-1} p_{i}$$
(III. 66)

Les points clefs de cette technique sont la normalisation des degrés d'appartenance des niveaux de gris dans chaque classe, et la prise en considération des éléments en dehors de l'intervalle d'incertitude.

#### b/ Variante 2

Les deux distributions précédentes sont légèrement modifiées :

$$D_f: \frac{\mu_f(0).p_0}{P_f}, \frac{\mu_f(1).p_1}{P_f}, \dots, \frac{\mu_f(N_G-1).p_{N_G-1}}{P_f}$$
(III.67)

$$D_b: \frac{\mu_b(0).p_0}{P_b}, \frac{\mu_b(1).p_1}{P_b}, \dots, \frac{\mu_b(N_G-1).p_{N_G-1}}{P_b}$$
(III.68)

$$P_f = \sum_{i=0}^{s+k} \mu_f(i). p_i$$
 et  $P_b = \sum_{i=s-k}^{N_G-1} \mu_b(i). p_i$ 

Dans ce cas, les distributions prennent en compte la fréquence et le degré d'appartenance de chaque niveau de gris, associés directement au moyen d'une multiplication et normalisées dans chaque classe. Grace à cette association, les basses fréquences de niveaux de gris peuvent, si c'est le cas, être compensées par une forte appartenance à la classe. La mesure d'information associée à la séparation par un seuil s est :

$$HF(X \setminus s, k) = HF(b \setminus s, k) + HF(F \setminus s, k)$$

$$= -\sum_{i=0}^{s-k-1} \left[ \frac{P_i}{P_f} \ln\left(\frac{P_i}{P_f}\right) + \left(1 - \frac{P_i}{P_f}\right) \ln\left(1 - \frac{P_i}{P_f}\right) \right]$$

$$-\sum_{i=s-k}^{s+k} \left[ \frac{\mu_f(i) \ p_i}{P_f} \ln\left(\frac{\mu_f(i) \ p_i}{P_f}\right) + \left(1 - \frac{\mu_f(i) \ p_i}{P_f}\right) \ln\left(1 - \frac{\mu_f(i) \ p_i}{P_f}\right) \right]$$

$$-\sum_{i=s-k}^{s+k} \left[ \frac{\mu_b(i) \ p_i}{P_b} \ln\left(\frac{\mu_b(i) \ p_i}{P_b}\right) + \left(1 - \frac{\mu_b(i) \ p_i}{P_b}\right) \ln\left(1 - \frac{\mu_b(i) \ p_i}{P_b}\right) \right]$$

$$-\sum_{i=s+k+1}^{N_G-1} \left[ \frac{p_i}{P_b} \ln\left(\frac{p_i}{P_b}\right) + \left(1 - \frac{p_i}{P_b}\right) \ln\left(1 - \frac{p_i}{P_b}\right) \right]$$
(III. 69)

Le seuil optimal est celui qui minimise  $HF(X \setminus s, k)$ 

#### III.6.5 Seuillage entropique de Shanbag

Shanbag [48] considère les degrés d'appartenance d'un niveau de gris au fond ou a l'objet. En fait, plus la valeur du niveau de gris est éloignée du seuil s, plus le potentiel d'appartenance à une classe spécifique est grand. Ainsi, pour chaque pixel de l'objet ou du fond qui a g niveaux de gris au dessus ou au dessous d'un seuil s donné, on a les degrés d'appartenance suivants :

$$\mu_f(s-g) = 0.5 + \frac{p(s) + \dots + p(s-1-g) + p(s-g)}{2P(s)}$$
(III.70)

C'est-à-dire que sa mesure d'appartenance à l'objet est donnée par :

$$\mu_b(s+g) = 0.5 + \frac{p(s+1) + \dots + p(s-1+g) + p(s+g)}{2P(1-p(s))}$$
(III.71)

La valeur du seuil s doit correspondre au niveau de gris qui possède le maximum d'incertitude tel que :

$$\mu_b(s) = \mu_f(s) = 0.5 \tag{III.72}$$

Le seuil optimal est déterminé pour la valeur de *s* qui minimise la somme des entropies floues suivantes :

$$s_{opt} = \arg_g \min\{|H_f(s) - H_b(s)|\}$$
(III.73)

où

$$H_{f}(s) = -\sum_{g=0}^{3} \frac{p(g)}{P(s)} log \left[ \mu_{f}(g) \right]$$
(III.74)

et

$$H_b(T) = -\sum_{g=T+1}^{N_G-1} \frac{p(g)}{1 - P(s)} \log[\mu_b(g)]$$
(III.75)

$$P(s) = \sum_{g=0}^{s} \frac{gh(g)}{N}$$
 (III.76)

# III.7 Maximisation de la divergence floue

Soit A et B deux ensembles flous définis dans  $X = \{x_0, x_{1,...,i}, x_{N-1}\}$  tel que  $0 < \mu_A(x_i)$ ,  $\mu_A(x_i) < 1 \forall i$ . La divergence floue est une mesure de différence entre deux ensembles flous A et B, elle est donnée par :

$$D(A,B) = \frac{1}{N} \sum_{i=0}^{N-1} [D_i(A,B) + D_i(B,A)]$$
(III.77)

où  $D_i(A, B)$  et  $D_i(B, A)$  sont définis par les équations ci-dessous.

$$D_i(A,B) = \mu_A(x_i) ln \frac{\mu_A(x_i)}{\mu_B(x_i)} + \left[1 - \mu_A(x_i)\right] ln \frac{1 - \mu_A(x_i)}{1 - \mu_B(x_i)}$$
(III.78)

$$D_i(B,A) = \mu_B(x_i) ln \frac{\mu_B(x_i)}{\mu_A(x_i)} + \left[1 - \mu_B(x_i)\right] ln \frac{1 - \mu_B(x_i)}{1 - \mu_A(x_i)}$$
(III.79)

$$= -\mu_B(x_i) ln \frac{\mu_A(x_i)}{\mu_B(x_i)} - \left[1 - \mu_B(x_i)\right] ln \frac{1 - \mu_A(x_i)}{1 - \mu_B(x_i)}$$

La seconde partie de (III.78) et (III.79) prend en compte la divergence entre les compléments de A et B, mais ces équations ne servent pas à mesurer la divergence entre deux

ensembles classiques car pour chaque élément  $x_i$  on a soit  $\mu_A(x_i) = 0$ , soit  $\mu_B(x_i) = 0$ . Pour tenir compte des ensembles classiques, les equations (III.78) et (III.78)seront remplacées par :

$$D_i(A,B) = \mu_A(x_i) ln \frac{1 + \mu_A(x_i)}{1 + \mu_B(x_i)} + \left[1 - \mu_A(x_i)\right] ln \frac{2 - \mu_A(x_i)}{2 - \mu_B(x_i)}$$
(III.80)

$$D_i(B,A) = \mu_B(x_i) ln \frac{1 + \mu_B(x_i)}{1 + \mu_A(x_i)} + \left[1 - \mu_B(x_i)\right] ln \frac{2 - \mu_B(x_i)}{2 - \mu_A(x_i)}$$
(III.81)

$$= -\mu_B(x_i) ln \frac{1 + \mu_A(x_i)}{1 + \mu_B(x_i)} - \left[1 - \mu_B(x_i)\right] ln \frac{1 - \mu_A(x_i)}{1 - \mu_B(x_i)}$$

D'après (III.80) et (III.81), l'équation (III.77) peut s'écrire comme :

$$D(A,B) = \frac{1}{N} \sum_{i=0}^{N-1} \left[ (\mu_A(x_i) - \mu_B(x_i)) ln \frac{1 + \mu_A(x_i)}{1 + \mu_B(x_i)} + (\mu_B(x_i) - \mu_A(x_i)) ln \frac{2 - \mu_A(x_i)}{2 - \mu_B(x_i)} \right]$$
(III.82)

La maximisation de la divergence floue peut être utilisée pour trouver le niveau de gris le plus ambigu dans l'histogramme **[42].** On doit donc choisir, l'intervalle d'incertitude [s - k, s + k] et poser  $\mu_b(s) = \mu_f(s) = 0.5$ , s étant l'élément le plus ambigu. Pour cela, la fonction  $S_z$  se montre tout à fait cohérente. Comme  $\mu_b(s) + \mu_f(s) = 1 \forall x_i \in X, D_i(b, f) =$  $D_i(f, b)$ . Le critère de maximisation de la divergence entre l'objet et le fond, peut s'écrire de la manière suivante :

$$\max\left\{\frac{2}{N}\sum_{g=0}^{N_{G}-1}D_{i}(b,f)h(g)\right\}$$
(III.83)

ou  $D_i(b, f)$  est donnée par l'équation(III. 80). Par conséquent le seuil optimal s est :

$$s = \max\left\{\frac{2}{N_G - 1} \sum_{g=0}^{N_G - 1} [2 \,\mu_b(g) - 1] ln \frac{1 + \mu_b(g)}{2 - \mu_b(g)} h(g)\right\}$$
(III.84)

Une autre méthode de seuillage basée sur la divergence floue à été proposée par *Chaira* et *Ray* **[35].** 

La divergence floue d'une image *X* est déterminée à partir de l'entropie exponentielle définie comme suit :

$$H(A) = \frac{1}{NM(\sqrt{e} - 1)} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} \mu(x_{ij}) e^{1 - \mu(x_{ij})}$$
(III.85)

où  $\mu(x_{ij})$  est définie comme dans l'équation (III.25).

La divergence entre deux images X et Y est :

$$D_{i}(X,Y) = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} [1 - (1 - \mu_{X}(x_{ij}))e^{\mu_{X}(x_{ij}) - \mu_{Y}(x_{ij})} - \mu_{X}(x_{ij})e^{\mu_{Y}(x_{ij}) - \mu_{X}(x_{ij})}] \quad (\text{III. 86})$$

Ainsi la divergence totale est :

$$D(X,Y) = D_1(X,Y) + D_2(Y,X)$$

$$= \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} [2 - (1 - \mu_X(x_{ij}) + \mu_Y(x_{ij}))e^{\mu_X(x_{ij}) - \mu_Y(x_{ij})} - (1 - \mu_Y(x_{ij}) + \mu_X(x_{ij}))e^{\mu_Y(x_{ij}) - \mu_X(x_{ij})}]$$
(III. 87)

Dans le cas de seuillage, X correspond à l'image originale et Y à l'image segmentée idéale. Pour cette dernière image  $\mu_Y(x_{ij})$  est toujours égal à 1. Par conséquent, la divergence floue devient :

$$D(X,Y) = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} [2 - (2 - \mu_X(x_{ij}))e^{\mu_X(x_{ij}) - 1} - \mu_X(x_{ij})e^{1 - \mu_X(x_{ij})}] \quad (\text{III.88})$$

qu'on peut mettre sous la forme :

$$D(X,Y) = \sum_{g=0}^{N_G-1} [2 - (2 - \mu(g))e^{\mu(g)-1} - \mu(g)e^{1-\mu(g)}]$$
(III.89)

Le seuil optimal peut être déterminé en minimisant D(X, Y).

*Chaira* et *Ray* **[34]** ont également proposé la similarité floue entre les images *X* et *Y* comme critère pour calculer le seuil :

$$S(X,Y) = \frac{1}{NM} \sum_{g=0}^{N_G-1} \mu(g)$$
(III.90)

Le seuil optimal peut être obtenu en minimisant S(X, Y).

#### III.8 L'utilisation des mesures de probabilités

Soit deux ensembles disjoints  $X_1 = \{0, 1, ..., k_1\}$  et  $X_2 = \{k_1+1, k_1+2, ..., k_2\}$ .

Soit un ensemble flou *D*, avec sa fonction d'appartenance  $\mu_D(x_i, x_j)$  qui détermine la dissimilarité entre  $x_i$  et  $x_j$  ne soient pas similaires. La probabilité que  $X_1$  et  $X_2$  ne soient similaires (c.-à-d. la mesure de dissimilarité entre  $X_1$  et  $X_2$ ) est donnée par [42]

$$P = \sum_{i \in X_1} \sum_{j \in X_2} Diss(i, j) P(i \in X_1) P(j \in X_2)$$
(III.91)

où

$$P = \sum_{i=1}^{k_1} \sum_{j=k_1+1}^{k_2} \mu_D(x_i, x_j) P(x_i, X_1) P(x_j, X_2)$$
(III.92)

où  $P(x_i, X_1)$  et  $P(x_i, X_2)$  est la probabilité de  $X_1$  et  $X_2$  respectivement.

Pour appliquer cette mesure de dissimilarité à l'histogramme des niveaux de gris, on considère pour chaque seuil *s* possible,  $k_1$  et  $k_2$  comme étant *s* et  $N_G$  – 1 respectivement. La fonction  $\mu_D$  entre 2 niveaux de gris *g* et  $\bar{g}$  peut être définie de plusieurs manières :

$$\mu_D(g,\bar{g}) = \frac{|g-\bar{g}|}{N_G - 1}$$
(III.93)

$$\mu_D(g,\bar{g}) = 1 - e^{-|g-\bar{g}|}$$
(III.94)

Selon la distribution de probabilité de la classe fond P(g,b) et la classe objet P(g,f), on peut sélectionner le seuil *s* qui maximise la probabilité *P* de façon paramétrique ou non paramétrique.

$$P = \sum_{g=1}^{k_1} \sum_{\bar{g}=k_1+1}^{k_2} \mu_D(g,\bar{g}) P(g,b) P(\bar{g},f)$$
(III.95)

#### **III.8.1** Non paramétrique

Dans ce cas, on considère l'histogramme comme représentant de deux distributions de probabilité. Le seuil optimal est :

$$s^* = \max_{s=0\dots N_G - 1} \left\{ \sum_{g=0}^{s} \sum_{\bar{g}=s+1}^{N_G - 1} \mu_D(g, \bar{g}) \frac{h(g)}{\sum_{k=0}^{s} h(k)} \frac{h(\bar{g})}{\sum_{k=s+1}^{N_G - 1} h(k)} \right\}$$
(III.96)

#### **III.8.2** Paramétrique

Les deux distributions de probabilité, celle de fond et celle de l'objet, peuvent être approchées par deux lois normales ou deux distributions de poisson. Dans le premier cas, le seuil optimal est celui qui maximise :

$$P(s) = \frac{1}{\sigma_1(s)\sigma_2(s)} \frac{1}{2\pi} \sum_{g=0}^{s} \sum_{\bar{g}=s+1}^{N_G-1} \mu_D(g,\bar{g}) e^{-\frac{1}{2} \left(\frac{g-m_1(s)}{\sigma_1(s)}\right)^2} e^{-\frac{1}{2} \left(\frac{\bar{g}-m_2(s)}{\sigma_2(s)}\right)^2}$$
(III.97)

où

$$m_k(s) = \frac{\sum_{g=a}^{b} gh(g)}{\sum_{g=a}^{b} h(g)} \quad \text{et} \quad \sigma_k^2(s) = \frac{\sum_{g=a}^{b} [1 - m_k(s)]^2 h(g)}{\sum_{g=a}^{b} h(g)} \quad (\text{III. 98})$$

pour

$$a = \begin{cases} 0 & k = 1 \\ s+1 & k = 2 \end{cases} \quad \text{et} \quad b = \begin{cases} s & k = 1 \\ N_G - 1 & k = 2 \end{cases}$$

Dans le deuxième cas, le seuil optimal est :

$$s^* = max_{s=0,1,\dots,N_G-1} \left\{ \sum_{g=0}^{s} \sum_{\bar{g}=s+1}^{N_G-1} \mu_D(g,\bar{g}) \frac{\left(m_1(s)\right)^g}{g!} e^{-m_1(s)} \frac{\left(m_2(s)\right)^{\bar{g}}}{\bar{g}!} e^{-m_2(s)} \right\}$$
(III.99)

$$m_1(s) = \frac{\sum_{g=0}^{s} g h(g)}{\sum_{g=0}^{s} h(g)} \quad \text{et} \quad m_2(s) = \frac{\sum_{g=s+1}^{N_G-1} g h(g)}{\sum_{g=s+1}^{N_G-1} h(g)} \quad (\text{III. 100})$$

#### **III.8** Conclusion

Dans l'étude menée sur les différentes techniques de seuillage flou, nous nous somme limité aux techniques qui introduisent les notions de la logique floue type-1. Ces techniques sont nombreuses et diffèrent soit par la manière de calculer le degré d'appartenance d'un pixel à une classe, soit par le critère d'optimisation utilisé pour choisir le seuil optimal.

Notons qu'une autre technique de seuillage basée sur la logique floue de type-2 à été récemment proposée. Elle fait appel aux fonctions d'appartenance qui sont elle-même floues, par conséquence le degré d'appartenance d'un pixel à une classe n'est pas unique, ce qui nécessite l'utilisation de raisonnement flou en deux fois, cela offre beaucoup de possibilité pour déterminé le seuil optimal.

Parmi toutes les méthodes étudiées dans ce chapitre, nous allons nous intéresser particulièrement à deux méthodes à savoir celle de *Huang* et *wang* et celle de *Jawahar* et *al*.

# <u>Chapitre VI</u>: Tests et résultats.

#### VI.1 Introduction

Comme dans de nombreux problèmes de segmentation d'image, la validation des résultats obtenus demeure un problème délicat. Plusieurs approches peuvent être envisagées dans le but de fournir une évaluation quantitative de la qualité des résultats.

Pour aboutir à notre objectif, nous avons fait recourt au logiciel *MaTlab* (version 7.8) avec lequel nous avons implémenté quatre méthodes parmi celles évoquées dans les *chapitre I* et *chapitre III*, à savoir les méthodes *Hard d'Otsu* et de *Kapur* et les méthodes *soft* de *Huang* et *wang* et de *Jawahar* et *al*.

Pour déterminer la méthode qui donne le meilleur seuil qui sépare l'objet du fond, nous avons fait appel à deux critères de comparaison qui exploitent les résultats obtenu par les algorithmes implémentés. Ces critères de comparaison sont des fonctions qui utilisent le seuil obtenu par l'algorithme de seuillage pour calculer le degré d'uniformité ou le degré de divergence entre l'image aux niveaux de gris et l'image seuillée. Contrairement aux méthodes d'évaluation supervisées qui ont besoin d'une image référence, les méthodes d'évaluation non supervisées sont quantitatives et objectives, elles calculent le degré de ressemblance entre les caractéristiques de l'image segmentée et celles désirées. Nous avons également utilisé le temps de calcul comme critère de comparaison. L'ordinateur sur lequel, nous avons effectué tous nos tests est doté d'un microprocesseur de type *Intel Core2Duo à 2.26 Ghz/s* et de *4Gbits* de mémoire vive.

#### VI.2 Critères de comparaison des résultats

#### VI.2.1 Uniformité

Livin et Nazif ont proposé l'indice ci-dessous pour la mesure d'uniformité :

$$U = 1 - 2(K - 1) \frac{\sum_{i=1}^{K} \sum_{j \in R_i} (g_j - m_i)^2}{N(g_{max} - g_{min})^2}$$

avec :

 $g_i$ : est le niveau de gris de  $i^{eme}$  pixel.

 $R_j$ : représente la  $j^{eme}$  région segmentée avec j = 1, 2, ... K.

K : nombre de classes (nombre de régions segmentées).

(*K*-1) : représente le nombre de seuils.

N: nombre total des pixels.

 $g_{max}, g_{min}$  Sont respectivement les valeurs maximales et minimales des niveaux de gris.

 $m_i$ : la moyenne des niveaux de gris des pixels de la region  $R_i$ .

Dans le cas de binarisation on aura :

 $g_i$ : est le  $i^{eme}$  niveau de gris de pixel.

 $R_j$ : représente le fond ou l'objet avec j = 1, 2.

K: nombre de classes avec K = 2.

(K-1) = 1 : un seul seuil.

 $m_k$ : La moyenne des niveaux de gris des pixels de la région fond lorsque *K* est la classe fond, ou de la région objet lorsque *K* est la classe objet.

Les valeurs de U sont comprises entre 0 et 1. La valeur maximale de U nous donne le meilleur résultat de segmentation.

## VI.2.2 Divergence entre l'image originale et sa version seuillée

L'indice ci-dessous sert comme outil de mesure de différence des niveaux de gris entre l'image originale (aux niveaux de gris) et sa version segmentée (image seuillée).

$$D = \frac{1}{N} \sqrt{\sum_{i=1}^{N} (g_i - thresh_i(k))^2}$$

avec :

 $g_i$ : est le niveau de gris de  $i^{eme}$  pixel.

*thresh*<sub>i</sub>(K) : est le niveau de gris de  $i^{eme}$  pixel de l'image segmentée par (K-1) seuils. Il correspond à la moyenne des niveaux de gris de la classe  $C_k$  défini comme suit :

$$thresh_{i}(k) = \begin{cases} m_{k} & si \ i \in C_{k} \\ 0 & ailleur \end{cases}$$

Dans le cas de binarisation, c'est-à-dire K = 2 classes (fond et objet) on aura :

 $g_i$ : est le  $i^{eme}$  niveau de gris.

*thresh*<sub>*i*</sub>(k) =s : est le seuil de binarisation.

La valeur minimale de *D* nous donne le meilleur résultat de segmentation.

#### VI.3 Résultats et comparaison

Dans cette section nous allons présenter les résultats des différentes méthodes de seuillage obtenues sur des images réelles appartenant à des domaines d'application différents. Chaque image sera décrite par son histogramme, l'objet à extraire par l'opération de seuillage sera également mentionné.

#### VI.3.1 Domaines d'application

Les images réelles utilisées dans nos tests sont issues de plusieurs domaines d'application.

#### VI.3.1.1 Médical

Deux images IRM (coupe horizontal du cerveau d'une personne malade de *sclérose en plaques*) sont utilisées. Dans ces images, notre objectif est de faire apparaitre les zones qui sont atteintes par la maladie de *sclérose en plaques* qui est une maladie inflammatoire du système nerveux central dont les cellules atteintes par la maladie prennent une couleur légèrement différente de celle des cellules du système central. Dans les images IRM du scanner, il est difficile de distinguer le niveau de gris des zones malades de celle du système nerveux, pour cette raison nous allons effectuer un seuillage sur des images IRM d'un malade de *sclérose en plaques* pour séparer les zones touchées par la maladie du reste de système nerveux dans le but de facilité au médecin de suivre l'évolution de la maladie en calculant par exemple la surface ou le volume des zones touchées par la maladie.

Les figures (IV.1) et (IV.2) montrent les images originales en niveaux de gris ainsi que leurs histogrammes. Sur ces images, on peut distinguer visuellement 4 classes de pixels ayant des niveaux de gris différents. Cependant, les histogrammes font apparaître que deux modes.

Le  $1^{er}$  mode est relatif aux pixels noirs, le  $2^{em}$  correspond à la matière grise et aux taches blanches.



Fig. IV.1 : Image originale IRM 1 et son histogramme.



Fig. IV.3 : Image originale IRM 2 et son histogramme.

Les *tableaux* (VI.1) et (IV.2) regroupe les valeurs des seuils et des critères de comparaison obtenus par les quatre méthodes de seuillage. Les *figures* (VI.2) et (VI.3) montrent les images binaires correspondantes.

Algorithmes Critères de comparaison	Otsu	Kapur	Huang et Wang	Jawahar et al. $\tau=1.5, \epsilon=0.01$
Seuil optimal	50	123	16	52
Critère Uniformité	0.98740	0.95155	0.98240	0.98741
Critère de Divergence	0.042442	0.083012	0.050676	0.042413
Temps de calculs (s)	0.0097267	0.6892100	0.2775700	0.4278300

Tableau. IV.1 : Résultats de seuillage de l'image IRM 1.

Algorithmes Critères de comparaison	Otsu	Kapur	Huang et Wang	Jawahar et al. $\tau$ =1.5, $\varepsilon$ = 0.01
Seuil optimal	43	122	18	45
Critère Uniformité	0.99319	0.95832	0.99066	0.99319
Critère de Divergence	0.031219	0.077029	0.036912	0.031177
Temps de calculs (s)	0.0040058	0.6554100	0.2145700	0.5348100

**Tableau. IV.2** : Résultats de seuillage de l'image IRM 2.

Image Otsu



Image Huang









Fig. IV.2 : Image IRM 1 binarisée

Image Otsu



Image Huang



# lmage Kapur





Fig. IV.4 : Image IRM 2 binarisée.

En se référant aux deux critères de comparaison (Uniformité et Divergence), la méthode de *Jawahar* et *al* est la plus performante. Le seuil fournit par la méthode de *Jawahar* et *al* est proche de celui d'*Otsu*. Cependant, d'un point de vue temps de calcul, la méthode d'*Otsu* est la plus rapide. Cependant, on peut remarquer que seule la méthode de *Kapur* a permis de séparer les pixels de la *sclérose* (taches blanches) des autres pixels même si son seuil se situe en dehors de la vallée principale de l'histogramme.

# VI.3.1.2 Industrie

L'image de la figure (*IV.5*) est une image d'un verre ayant un défaut présenté sous un cercle. L'objectif de seuillage de cette image est la détection des défauts de fabrication dans les plaques de verre. On remarque que l'histogramme de cette image est bimodal avec une vallée très grande qui représente le fond et une autre vallée très petite entre *150* et *170* qui représentent l'objet (défaut).



Fig. IV.5 : Image d'un verre et son histogramme.

Le *tableau (IV.3)* regroupe les valeurs des seuils et des critères de comparaison obtenus par les 4 méthodes de seuillage. La *figure (VI.6)* montre les images binaires correspondantes. D'après le tableau (*IV.3*), on constate que les critères d'uniformité, de divergence et du temps de calcul sont la méthode d'Otsu et la plus efficace. Mais de point de vu détection du défaut, la méthode d'Otsu n'a rien donné, contrairement aux deux méthodes *soft, Huang* et *wang* et *Jawahar* et al (avec  $\tau = 2.5$ ) qui ont donné des résultats satisfaisants et parfaitement identiques le défaut est non seulement mis en évidence et même les rayures laissées par le processus de fabrication sont mises en évidence. Pour la méthode de *Kapur*, on constate qu'elle a donné des résultats meilleurs au sens d'uniformité et divergence que les deux dernières méthodes, mais de point de vu du défaut elle est moins bonne que ces deux dernières.

Algorithmes Critères de comparaison	Otsu	Kapur	Huang et Wang	Jawahar et al. $\tau$ =2.5, $\varepsilon$ = 0.01
Seuil optimal	69	153	180	180
Critère Uniformité	0.99966	0.99946	0.99935	0.99935
Critère de Divergence	0.0023654	0.0029189	0.0032955	0.0032955
Temps de calculs (s)	0.024292	0.870600	0.189660	0.459290

Tableau. IV.3 : Résultats de seuillage de l'image de verre.







Fig. IV.6 : Image de verre binarisée.

### VI.3.1.3 Sécurité

En biométrie, on cherche souvent à reconnaitre ou à identifier une personne à partir de son empreinte digitale.

L'objectif de seuillage dans cette image est de faire des rectifications sur l'empreinte digitale pour faire apparaitre plus de détails. Sur l'image originale il est très difficile de reconnaitre l'ensemble des traces de l'empreinte car il y a des niveaux de gris qu'ils sont très proches du blanc et qu'on ne peut pas voir, ce qui nécessite l'utilisation de l'opération de seuillage. D'après l'histogramme de l'image, on remarque qu'il y a peut de pixel qui ont un niveau de gris inferieur a 200, la plupart des vallées se trouvent entre 200 et 256, ce qui signifie que le seuil optimale doit être contenu dans cet intervalle.



Fig. IV.7 : Image d'une empreinte et son histogramme.

Le *tableau (IV.4)* regroupe les valeurs des seuils et des critères de comparaison obtenus par les 4 méthodes de seuillage. La *figure (VI.8)* montre les images binaires correspondantes. En se référant aux trois critères de comparaison (Uniformité, Divergence et temps de calcul), la méthode *d'Otsu* est aussi la plus performante.

Toutefois, on remarque que la méthode de *Huang* et *Wang* a bien reconstitué les parties non visibles sur l'image originale. La méthode de *Jawahar* et *al* a donné un résultat proche de celui de *Huang* et *Wang* lorsqu'on fixe le paramètre  $\tau$  à 4.78. D'un point de vu reconstitution des traces de l'empreinte, et de point de vu uniformité, les résultats sont très proches de ceux d'*Otsu*, ce qui signifie que cette méthode donne de bonnes résultats pour ce genre d'image.

Algorithmes Critères de comparaison	Otsu	Kapur	Huang et Wang	Jawahar et al. $\tau$ =4.78, $\varepsilon$ = 0.01
Seuil optimal	196	1	239	227
Critère Uniformité	0.98581	0.93958	0.97488	0.98074
Critère de Différence	0.077820	0.160550	0.102460	0.089887
Temps de calculs (s)	0.0019936	0.6956100	0.1658500	0.3061500

**Tableau. IV.4** : Résultats de seuillage de l'image empreinte.





Image Huang





Fig. IV.8 : Image empreinte binarisée.

## VI.3.1.4 Astronomie

En astronomie, on utilise souvent des images issues de télescopes afin de scruter l'immense espace.

L'objectif de seuillage pour ces images, est de faire apparaitre l'existence des étoiles au voisinage de la galaxie lorsqu'il s'agit d'une recherche d'étoiles, ou au contraire faire cacher les étoiles qui ont moins de luminance pour faire apparaître le centre de la galaxie ou les endroits les plus clairs.

La figure (IV.9) montre une image de galaxie avec son histogramme.


Fig. IV.9 : L'image de galaxie 1 et son histogramme

Le *tableau (IV.5)* regroupe les valeurs des seuils et des critères de comparaison obtenus par les 4 méthodes de seuillage. La *figure (VI.9)* montre les images binaires correspondantes. L'histogramme de cette image et multimodal ce qui justifie l'existence de plusieurs objets dans l'image avec des niveaux de gris qui varient de l'objet à l'autre. On remarque que presque tout les pixels ont un niveau de gris supérieur a 50 ce qui justifie le résultat obtenu par la méthode de *Kapur (Fig.IV.10)*. En ce qui concerne les détails, on remarque que la méthode *d'Otsu* fait apparaître beaucoup d'objet dans l'image par rapport à celle de *Huang* et *Wang*. La méthode de *Jawahar* et *al.* est celle qui donne moins de détails par rapport à la méthode d'*Otsu* et celle de *Huang* et *Wang* pour un  $\tau$ =1.1. Cependant, elle fait bien apparaître les objets qui ont une grande luminance. On remarque que l'apparition d'objet dans l'image diminue avec l'augmentation de seuil, chose que nous avons constaté lors de la variation de facteur flou  $\tau$  dans la méthode de *Jawahar* et *al.* Les résultats sont affichés dans la figure (*IV.11*).

En se référant aux trois critères de comparaison (Uniformité, Divergence et temps de calcul), la méthode *d'Otsu* et celle qui donne les meilleurs résultats. En comparant les valeurs de Tableau (*IV.5*) entre ces trois méthodes on constate que la méthode de *Jawahar* et *al* est très proche de la méthode d'*Otsu* au sens d'uniformité et de divergence. La figure (*IV.11*)

montre comment varis la valeur du seuil dans la méthode de *Jawahar* et *al* en fonction de  $\tau$ . Donc d'après nos constatations, on peut favoriser la méthode de *Jawahar* et *al* par rapport aux autres puisqu'elle nous offre la possibilité de calculer plusieurs seuils optimaux avec la variation de  $\tau$  qui nous permettra de parvenir à notre objectif. De ce fait la prochaine section de ce chapitre sera réservée à l'étude de la méthode de *Jawahar* et *al*.

Algorithmes Critères de comparaison	Otsu	Kapur	Huang et Wang	Jawahar et al. τ=1.1, ε= 0.01
Seuil optimal	108	49	105	116
Critère Uniformité	0.99577	0.98836	0.99527	0.99569
Critère de Divergence	0.022982	0.038152	0.024538	0.023207
Temps de calculs (s)	0.010651	0.875800	0.333060	0.525510

**Tableau. IV.5** : Résultats de seuillage de l'image galaxie 1.

### Image Otsu



Image Huang





Fig. IV.10 : Image de galaxie 1 binarisée.



Fig. IV.11 : Variation de seuil de Jawahar et al en fonction du paramètre flou To.

### VI.3.2 Etude de la méthode de Jawahar et al

La méthode de seuillage de *Jawahar* et *al* dépend principalement du facteur flou  $\tau$ . Nous avons par conséquent étudié son influence sur les résultats de la méthode. Pour cela nous effectuons nos tests sur une autre image de galaxie (*Fig.IV.12*).

Cette image a presque le même histogramme que celui de l'image de la figure (*IV.9*), donc l'objectif reste le même, sauf que dans ce cas les résultats obtenus varient selon la variation d'un seul paramètre qui est  $\tau$  dans la méthode de *Jawahar* et *al*, après plusieurs tests on peut conclure que cette méthode donne des résultats admissible pour la variation de  $\tau$ entre *1.1* et 5 pour la plupart des images sur les quelles nous avons effectué nos tests.

Les résultats sont représentés sous forme de graphe dans (*Fig. IV.13*). Le 1<sup>er</sup> graph représente la variation du seuil en fonction de  $\tau$ . De ce graphe on déduit que pour cette image les valeurs des seuils admissibles sont donnés pour  $\tau$  appartenant a l'intervalle [1.1 4.1]. Et grâce aux 2<sup>em</sup> et 3<sup>em</sup> graphes qui décrivent la variation des critères d'uniformité et de divergence respectivement en fonction de  $\tau$ , on peut comparer entre les différentes méthodes implémentées avec celle de *Jawahar* et *al* grâce au intervalles sur les quelles on peut comparer les différentes valeurs d'uniformité et de divergence des différentes méthodes telles qu'il est illustré dans la (*Fig. IV.13*).



Fig. IV.12 : Image de galaxie 2 et son histogramme.



Fig. IV.13 : Variation des différents critères de comparaison en fonction de To.

#### VI.4 Conclusion

D'après l'étude menée sur l'implémentation des algorithmes et les tests effectués sur différentes images issues de plusieurs domaines d'application, on a peut voir les différents avantages que possèdent les méthodes *soft* par rapport aux autres méthodes. L'avenage commun pour toutes ces méthodes est de s'adapte pour différentes type d'image, ce qui est le cas de la méthode de *Huang* et *Wang* qui a pratiquement donné de bons résultats visuels pour la majorité des images, et la méthode de *Jawahar* et *al* dont le degré d'uniformité et de divergence est très proches au meilleur que celui de la méthode a donné des résultats visuels plus intéressants que ceux donné par la méthode *d'Otsu* pour la majorité des images testés.

En conclusion on peut dire que globalement les méthodes *soft* donnent des résultats plus fiables au sens de tous les critères de comparaison.

# <u>Conclusion</u> <u>Générale</u>

### **Conclusion Générale**

Séparer les différentes entités qui composent une image d'une façon optimale, constitue un des problèmes les plus importants en traitement et analyse d'image. Cette opération casée obligatoire dans tous les systèmes de reconnaissance des formes et la segmentation. Celle-ci conditionne fortement la qualité de l'interprétation, ce qui justifie les nombreux travaux qui lui ont été consacré.

L'objectif de ce travail à été l'étude des différentes méthodes de seuillage qui utilisent les notions de la logique floue pour les comparées aux méthodes dites *hard* telles que les méthodes basées sur l'analyse discriminantes (*Otsu*), *Kapur* et la théorie de l'information évoquées dans le 1<sup>er</sup> chapitre. Notre objectif a été de déterminer le seuil optimal en utilisant les technique de seuillage basées sur le flou dont la particularité et de conserver le maximum d'information sur le degré d'appartenance des pixels aux différentes classes et de ne pas prendre une décision prématurément jusqu'à ce qu'on satisfasse certains contraintes.

D'une manière générale, les méthodes de seuillage flou se caractérisent par le critère utilisé pour déterminer un seuil optimal. Ce critère fait toujours intervenir le degré d'appartenance d'un niveau de gris à la classe fond ou objet et ces degrés peuvent être déterminé de plusieurs façons.

Parmi la multitude de méthodes de seuillage flou, nous nous somme intéressé à celle proposée par *Huang* et *Wang* et celle de *Jawahar* et *al*. Les résultats de ces deux méthodes se sont avérés meilleurs par rapport aux méthodes d'*Ostu* et de *Kapur*.

Cependant, il y a lieu de noter qu'il n'y a pas de méthodes de seuillage universelle qui soit meilleure quelque soit l'image à traiter.

Notre travail reste bien sure perfectible. Il serait intéressant d'étendre cette étude à d'autres méthodes de seuillage comme celles présentées dans le 3<sup>eme</sup> chapitre et aux méthodes de seuillage basées sur les principes de la logique floue de type-2.

# <u>Bibliographie</u>

## **Bibliographies**

- [1] http://fr.wikipedia.org/wiki/Pixel.
- [2] http://fr.wikipedia.org/wiki/Pixel#Dimension\_d.27un\_pixel.
- [3] http://urfist.enc.sorbonne.fr/anciensite/image\_numerique/notions.htm#structure.
- [4] http://www.kaddour.com/chap1/chap1.htm
- [5] R M HARALICK. Statistical and structural approaches to texture Proceedings of IEEE, 67(5) pp. 786-803, 1979.
- [6] J-P Cocquerez et S.PHILIPP. ANALYSE D'IMAGE : Filtrage et segmentation
- [7] http://www.developpez.net/forums/member.php?u=132655
- [8] N.R. PAL and S.K. PAL. A review of image segmentation techniques. PR,(9) pp. 1277-1294, 1993.
- [9] C. KERMAD, La Segmentation d'images 2D fixe : une revue. Rapport de Recherche interne LASTI-IMAGE 1994.
- [10] A.L. DAVIS. A survey of edge detection techniques. CGIP 4 pp.251-259, 1976.
- [11] Thèse Chafik Kermad. Segmentation d'image: recherche d'une mise en œuvre automatique par coopération de méthodes. -Université Rennes (1997).
- [12] J.S. WESKA. A survey of threshold selection techniques, CVGIP.7, pp.259-265, 1978.
- [13] S. WATANABE. An automated apparatus for cancer processing CYBEST, CVGIP.3, pp.350-358,1974.
- [14] J.N. KAPUR, P.K. SAHOO and A.K.C. WONG. A new method for gray-level picture thresholding using the entropy of histogtram, CVGIP.29,pp. 273-285, 1985.

- [15]: A.S. ABUTALEB. Automatic thresholding of gray-level pictures using two dimensional entropy, CVGIP 47 pp.22-32, 1989.
- [16] N. OSTU. Threshold selection method from gray-level histogram. T-SMC-8, pp.62-66, 1978.
- [17] L.Zadeh. "Fuzzy logic, Neural and soft computing". Communication of the ACM, vol. 37, no. 3, pp.77-84, 1994.
- [18] Jelana Godjevac. Une idée nette sur la logique floue. COLLECTION Informatique.
- [19] A. Rosenfeld. The fuzzy geometry of image subsets. Pattern Recognition Letters,(2):311-317, 1984.
- [20] Sankar K. Pal. Fuzzy skeletonization of an image. Pattern Recognition Letters, (10): 17-23, 1989.
- [21] G. J. Klir and B. Yuan, "Fuzzy sets and fuzzy logic; theory and application". Prentice Hall, 1994.
- [22] G.J.Klir and B. Yuan, "Fuzzy sets, Fuzzy Logic, and Fuzzy Systems". Advances in Fuzzy Systems, Application and theory, vol.6, 1996.
- [23] Thèse CHAFAA Kheireddine Structures d'identification et de commande des systèmes non linéaires basés sur les techniques floues. Université de Batna 1999.
- [24] N.N. Karnik, J. M. Mendel and Q.Liang. "Type-2 fuzzy logic systems", IEEE Trans. Fuzzy Syst, vol. 7, no. 6. pp. 643-658. 1999.
- [25] J. M. Mendel. "Fuzzy logic systems for engineering: A tutorial", IEEE proceedings, vol. 83, 3, pp. 345-377. 1995.
- [26] J.M. Mendel, "Computing Derivatives in Interval Type-2 Fuzzy Logic Systems", IEEE Trans. Fuzzy Syst, vol.12, no. 1, pp.84-98. 2004.
- [27] J.M. Mendel and R. I. B. John. "Type-2 fuzzy sets made simple". IEEE Trans. Fuzzy Syst, vol. 10, no. 2, pp. 117-127. 2002

- [28] Thèse Gilson BRAVIANO. Logique floue en segmentation d'image: seuillage par entropie et structures pyramidales irrégulières. Université Joseph Fourier- Gronoble 1. 1995.
- [29] Silviu Guiasu and Radu heo-dorescu. Incertitude et informatique. Les presses de l'université Laval. Québec. 1971.
- [30] A. de Luca and S. Termini. A definition of a non probabilistic entropy in the setting of fuzzy sets theory. Information and control, (20): 301-312, 1972.
- [31] W-B.Tao, J-W.Trian and J. Liw. Image segmentation by three\_level thresholding on maximum fuzzy entropy and genetic algorithm, Pattern recognition, vol.24, pp. 3069-3078, 2003.
- [32] H.D.Cheng, J-R. Chen and J. li. Theshold selection based on fuzzy c-partition entropy apparoch. Patten Recognition, vol.31, no.7, pp. 857-870,1998.
- [33] L.-K. Huang, M: J.J. Wang. Image thresholding by minimizing the measures of fuzziness. Pattern Recognition. Vol. 38, no.1, pp.41-51,1995.
- [34] T. Chaira and A.K Ray. Threshold selection using fuzzy set theory. Patten Recognition letters, vol.25, pp.865-874, 2004.
- [35] T. Chaira and A.K Ray. Segmentation using fuzzy divergence. Pattern Recognition letters, vol.24, pp.1837-1844, 2003.
- [36] C.V.Jawahar, P.K Biswas and A.K.Ray. Analysis of fuzzy thresholding schemes. Pattern Recognition, vol.33, pp.1339-1349, 2000.
- [37] H.D. Cheng, Y.-H. Chen and Y. Sun. A novel fuzzy entropy approach to image enhacement and thresholding, Signal Processing, vol.75, pp.277-301,1999.
- [38] W-B.Tao, J-W.Trian and J. Liw. Object segmentation using and colony optimization algorithm and fuzzy entropy. Pattern Recognition letters, vol.28, pp.788-796,2007.
- [39] D. Lina, Z. Jiang and H. Feng. A novel fuzzy classification entropy approach to image thresholding. Pattern Recognition, vol.27, pp.1968-1975.

- [40] A. de Luca and S. termini. A definition of a nonprobabilistic entropy in the setting of fuzzy sets theory. Information and Control, (20): 301-312, 1972.
- [41] Sankar K. Pal and Azriel Rosenfeld. Image enhancement and thresholding by optimization of fuzzy compactness. Pattern Recognition Letters, (7): 77-86, 1988.
- [42] Dinadundhu Bhandari, Nikhil R. Pal, and D. Dutta Majumber. Fuzzy divergence, probability measure of fuzzy events and image thresholding. Patrtern Recognition Lutters, (13): 857-867, 1992.
- [43] J. C. Bezdek. Pattern Recognition with fuzzy objective function algorithms. Plenum Press, New York, 1981.
- [44] J. C. Dunn. A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. Journal of Cybernetics, 3(3):32-57, 1974.
- [45] L.K. Huang and M.J.J. Wang,"Image thresholding by minimizing the measures of fuzziness". Pattern Recogn .28, 41-51 (1995).
- [46] S.K.Pal and A. Rosenfeld, "Image enhacement and threshoding by optimization of fuzzy compactness". Pattern Recogn.lett.7, 77-87 (1998).
- [47] C.V.Jawahar, P.K Biswas and A.K.Ray. Investigations on fuzzy thresholding based on fuzzy clustering. Pattern Recogition, vol.30, no.10, pp.1605-1613, 1997.
- [48] A. G. Shanbag, "Utilisation of information measure as a means of image thresholding". Comput. Vis. Graph. Image Process. 56, 414-419 (1994).
- [49] Survery over image thresholding techniques and quantitative performance evaluation.Mehmet Sezgin. Journal of Electronic Imaging 13 (1), 146-165 (January 2004).