

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



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

Mémoire de Fin d'Etudes

En vue de l'obtention du diplôme

De Master en Automatique

Thème

Techniques de seuillage flou
d'images

Proposé par et dirigé par :

Mr HAMMOUCHE.K

Présenté par :

FAREZ Abderezak

Promotion 2011

DEDICACES

*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.

A mon oncle Meziane

A mon cousin Hanafi

A tous mes amis et collègues d'études.

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

REMERCIEMENTS

Je remercie tous les membres de jury.

Je tiens à remercier mon promoteur Mr

HAMMOUCHE Kamel en lui exprimant ma sincère

*reconnaissance pour son aide et ses conseils tout au long de ce
travail.*

*Sans oublier Mr OTMANE CHERIF Tahar et Mlle CHILALI
pour leur aide.*

*Mes remerciements à ma famille ainsi que tous mes amis pour
leurs soutiens et leurs encouragements.*

Dieu merci

FAREZ Abderezak

Sommaire :

<i>Introduction générale</i>	1
------------------------------------	---

CHAPITRE I : Notions sur le traitement d'image

I.1 Introduction	3
I.2 Définition de l'Image	3
I.3 Technologie de l'image numérique	3
I.3.1 Terminologie.....	3
I.3.2 Caractéristiques d'une image numérique	3
➤ Pixel	4
➤ Dimension	4
➤ Résolution	4
➤ Bruit	4
➤ Histogramme	4
➤ Contours	5
➤ Textures	5
➤ Luminance	5
➤ Saturation	5
➤ contraste.....	6
➤ Images à niveaux de gris	6
➤ Images en couleurs	6
I.3.3 Les capteurs	7
I.3.4 Notions d'échantillonnage et de quantification.....	8
➤ Échantillonnage	8
➤ Quantification.....	8
I.3.5 Numérisation (discrétisation) de l'image	9
➤ Le voisinage d'un pixel	10
➤ Le codage binaire d'une image.....	10
I.3.6 Acquisition des données images	10

I.4 Opérateurs de traitement d'images	11
➤ Opérateurs image→image	11
➤ Opérateurs image→ensemble d'informations	12
➤ Opérateurs ensemble d'informations→image	12
I.4.1 Pré-traitement	12
➤ Filtres linéaires	12
➤ Lissage.....	13
➤ Modification de l'histogramme	13
• Recadrage de l'histogramme	14
• Égalisation de l'histogramme.....	14
I.4.2 segmentation	15
I.4.2.1 Méthode de segmentation	15
I.4.2.1.1 Approche contours	15
a)- Définition d'un contour actif	16
b)- Segmentation par Level Sets	16
I.4.2.1.2 Approche région	17
I.4.2.1.2.1 Segmentation par croissance de région	17
I.4.2.1.2.2 Segmentation par division-fusion	17
a)- Approche par division	17
b)- Approche par fusion	18
c)- Approche par division-fusion	18
I.4.2.1.2.3 Segmentation par classification	18
a)- Classification supervisée	19
b)- Classification non supervisée	19
I.4.2.1.3 Approche hybride	19
a)- Méthodes séquentielles	20
b)- Méthodes parallèles	20
c)- Méthodes hybrides	20
I.4.2.1.4 Seuillage	20
I.5 Méthodes de seuillage	22
I.5.1 Méthodes basées sur la transformation d'histogramme	22
I.5.2 Méthodes basées sur la théorie d'information	23
• Méthode de Kapur	23

I.5.3 Méthode basée sur l'analyse discriminante	24
I.6 Conclusion	25

CHAPITRE II : La logique floue en traitement d'image

II.1 Introduction	26
II.2 Concepts fondamentaux flous	27
II.2.1 Univers de discours	27
II.2.1.1 les Sous-ensembles flous	27
II.2.1.2 Fonction d'appartenance	27
➤ Exemple de fonction d'appartenance	27
• Fonction d'appartenance trapézoïdale	28
• Fonction d'appartenance exponentielle	28
• Fonction d'appartenance gaussienne	29
• Fonction d'appartenance singleton	29
II.2.1.3 Caractéristiques d'un sous-ensemble flou	30
• Le support	30
• Le noyau	30
• Les α –coupes	30
II.2.1.4 Opérations de base sur les ensembles flous	30
• Egalité	30
• Inclusion	31
• Intersection	31
• Union	31
• Normes et conormes triangulaires	31
• T-normes	31
• T-conormes	32
• Mesures floues	32
II.2.1.4.1 Produit cartésien et projection de sous-ensembles flous	33
• Le produit cartésien	33
• La projection	33

II.2.1.4.2 Géométrie floue	34
• La surface	34
• Le périmètre	34
• La compacité	34
• La hauteur et la largeur	34
• Connexité dans les ensembles flous	35
II.2.2 Variable linguistique	35
➤ Exemple de variable linguistique	36
II.2.3 Les règles d'inférences	36
II.2.4 Structure interne d'un système d'inférence floue	37
II.2.5 Procédure de raisonnement flou	37
➤ Fuzzification.....	37
➤ Base des règles floues	38
➤ Le raisonnement flou	38
➤ Défuzzification	38
II.3 Systèmes et modèles flous type-2	39
II.3.1 Concept des ensembles flous type-2	40
II.3.1.1 Types d'ensembles flous type-2	40
II.3.1.1.1 Ensemble type-2 Gaussien	40
II.3.1.1.2 Ensemble type-2 Intervalle	41
II.3.1.1.3 Ensemble type-2 Triangulaire	41
II.3.1.2 Représentation des ensembles flous type-2	41
II.3.2 Opérations algébriques	42
➤ Multiplication	42
➤ Addition	42
II.3.3 Système flou type-2	43
II.3.3.1 Fuzzification	43
II.3.3.2 Règle	43
II.3.3.3 Réduction de type	44
II.3.3.4 Déffuzzification	45
II.4 Conclusion	45

CHAPITRE III: Le seuillage flou

III. 1 Introduction	46
III.2 Segmentation floue	46
III.3 Méthodes de segmentation floue.....	47
III.3.1 L'intégration floue	47
III.3.2 Croissance de régions	47
III.3.3 La classification floue	48
• Algorithme FCM	48
III.4 Seuillage flou	49
III.4.1 Méthode basée sur l'algorithme FCM	50
• Méthode Jawahar et al	50
III.4.2 Méthodes basées sur l'indice flou	51
III.4.2.1 Indice flou	51
➤ Distance de Hamming ou linéaire	51
➤ Distance Euclidienne ou quadratique.....	51
III.4.2.2 Méthode de Chaira et Ray	52
III.4.3 Méthode basée sur la mesure d'incertitude	53
III.4.3.1 Mesure d'incertitude	53
III.4.3.2 Méthode de Huang et Wang.....	54
III.4.4 Méthode basée sur l'entropie floue	55
III.4.4.1 Entropie floue	55
III.4.4.2 Méthode Chang et al	56
III.4.4.3 Méthode de Tao et al	56
III.4.4.4 Méthode de Liu et al	58
III.4.4.5 Méthodes de Braviano	58
• Variante 1	58
• Variante 2	60
III.4.4.6 Méthode de Shanbag	60
III.4.5 Méthode basée sur la divergence floue	61
III.4.5.1 Divergence floue	61

III.4.5.2 Méthode de Bandari et al	62
III.4.5.3 Méthodes de Chaira et Ray	63
III.4.6 Méthode basée des mesures de probabilités	64
III.4.6.1 Principe	64
III.4.6.2 Méthode paramétrique	65
III.4.6.3 Méthode non paramétrique	65
III.4.7 Méthode basée sur la géométrie floue	65
III.4.7.1 Méthode de Pal	65
III.5. Conclusion	67

CHAPITRE IV : Test et Interprétation des résultats

IV.1 Introduction	68
IV.2 Critères de comparaison des résultats	68
IV.2.1 L'Uniformité :	68
IV.2.2 La Divergence entre l'image aux niveaux de gris et l'image seuillée	69
IV.3 Résultats et comparaison.....	69
IV.3.1 Médical	70
a)- Définition de l'IRM	70
b)-Image d'IRM	70
IV.3.2 L'Apiculture.....	75
a)- Définition de varroas	75
b)- Exemple	75
IV.3.3 Histoire	78
IV.4 Conclusion	82
<i>Conclusion générale</i>	83

Bibliographie

Introduction

Générale

Introduction Générale

Le traitement d'images est une discipline de l'informatique et des mathématiques appliquées qui étudie les images numériques et leurs transformations, dans le but d'améliorer leur qualité ou d'en extraire de l'information. Elle touche plusieurs domaines d'application, comme le traitement d'images médicales, la télédétection, la biologie, la surveillance (la reconnaissance des visages, des empreintes), etc.

Parmi toute la panoplie de techniques de traitement d'images, la segmentation apparaît comme une procédure très importante car elle permet d'identifier les composantes de l'image et faciliter donc sa compréhension. Elle consiste à découper une image en régions connexes présentant une homogénéité selon un certain critère lié au niveau de gris, la couleur ou la texture telle que l'union de ces régions doit redonner l'image initiale.

Plusieurs approches de segmentation d'images ont été proposées. Parmi elles le seuillage d'images constitue une manière simple et rapide de segmenter une image lorsque les objets qui la composent peuvent être discernés du fond de l'image. Cependant, en pratique cette opération peut être entachée d'incertitudes ou d'impression à cause des différents bruits qui contaminent l'image.

On s'intéresse dans ce mémoire aux méthodes de segmentation basées sur le raisonnement flou et plus exactement au seuillage flou. Le raisonnement flou 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'exprimer soit en termes d'ambiguïté d'appartenance d'un pixel à l'objet ou au fond, 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 précédents. L'introduction des mécanismes de la logique floue en segmentation d'image a pour objectif d'obtenir des résultats plus précis.

Ce mémoire présente une étude comparative entre plusieurs techniques de seuillage flou. Il est divisé principalement en quatre chapitres.

Le premier chapitre expose les notions de base sur le traitement d'image ainsi le processus de segmentation.

Le chapitre II présente quelques notions fondamentales des ensembles flous en décrivant leurs caractéristiques, les opérations sur les ensembles flous et leurs propriétés .

Le chapitre III est consacré à la description des différentes méthodes de seuillage flou présentes dans la littérature.

Le chapitre VI est destiné pour décrire les tests et les interprétations des résultats obtenus par les différentes techniques de seuillage flou, effectuées sur des images différentes et de domaines différents.

CHAPITRE I

*Notions sur le
traitement d'image*

I.1 Introduction

Avec la parole, l'image constitue l'un des moyens les plus importants qu'utilise l'homme pour communiquer avec autrui. Chacun peut analyser l'image à sa manière, pour en dégager une impression et d'en extraire des informations précises.

C'est ainsi que, le traitement d'images se propose comme 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.2 Définition de l'Image

L'image est un ensemble structuré d'informations qui, après affichage sur l'écran, ont une 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.

L'image numérique peut être ainsi représentée par une matrice de dimension $N \times M$, N qui est le nombre de lignes et M le nombre de colonnes. Chaque élément de la matrice, appelé pixel, le plus petit élément de l'image, représente l'intensité lumineuse comprise entre 0 et 255, soit 256 niveaux de gris (pour une image noir et blanc). Le noir correspond au niveau de gris 0 et le blanc le niveau de gris 255.

I.3 Technologie de l'image numérique

I.3.1 Terminologie

L'image numérique est obtenue à partir de l'échantillonnage du signal vidéo analogique fourni par des caméras ou des cameras CCD (Charge coupled device), des capteurs CMOS, CMOS (Foveon), des scanners ou échantillonneurs spécifiques. La résolution spatiale est le nombre de pixels dans l'image. La densité de résolution est le nombre de pixels par unité de longueur (ppi ou dpi).

I.3.2 Caractéristiques d'une image numérique [1]

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

➤ Pixel

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 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).

➤ 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 de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image.

➤ Résolution

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.

➤ 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.

➤ Histogramme [2]

Un histogramme est un graphique statistique permettant de représenter la distribution des intensités des pixels d'une image, c'est-à-dire le nombre de pixels pour chaque intensité lumineuse. Par convention un histogramme représente le niveau d'intensité en abscisse en allant du plus foncé (à

gauche) au plus clair (à droite). Ainsi, l'histogramme d'une image en 256 niveaux de gris sera représenté par un graphique possédant 256 valeurs en abscisses, et le nombre de pixels de l'image en ordonnées.

➤ **Contours**

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.

➤ **Texture**

Dans le domaine du traitement de l'image et de la vision, il n'existe pas de définition satisfaisante de la texture. Les définitions mathématiques construites à partir de propriétés statistiques sont soit trop générales et imprécises soit trop restrictives pour s'adapter à la diversité des cas rencontrés. La définition que nous proposons n'est pas opérationnelle et prête sur ce point à critique. Elle s'appuie sur une constatation expérimentale : une texture est un champ de l'image qui apparaît comme un domaine cohérent et homogène, c'est-à-dire formant un tout pour un observateur. C'est cette propriété de cohérence de la texture placée dans son contexte d'être perçue comme un tout homogène par l'œil humain qui sera recherchée le plus souvent par le traiteur des images, dans le but d'isoler les textures, soit pour segmenter l'image, soit pour reconnaître des régions.

➤ **Luminance**

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

➤ **Saturation**

À l'inverse de la luminosité, la saturation influence la perception subjective du caractère vif d'une couleur. Les comparaisons de couleurs suivantes, montrent respectivement au milieu la couleur de base, à gauche une variante avec une saturation moindre et à droite une variante avec une saturation plus élevée:

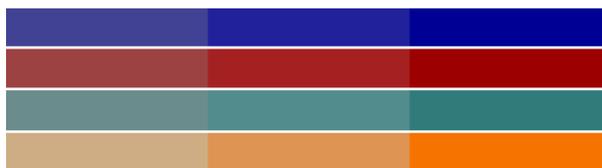


Fig.I.1- Des couleurs avec différentes saturations

En ce qui concerne la luminosité, les différents coloris ont été réglés environ sur la même luminosité. Les couleurs avec une saturation plus ou moins élevée semblent certes souvent au premier coup d'œil plus claires ou plus sombres mais c'est à l'évidence une conclusion fallacieuse.

➤ **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 variations de niveaux de gris.

➤ **Images à niveaux de gris**

Le niveau de gris est la valeur de l'intensité lumineuse en un point. La couleur du pixel peut prendre des valeurs allant du noir au blanc en passant par un nombre fini de niveaux intermédiaires. Donc pour représenter les images à niveaux de gris, on peut attribuer à chaque pixel de l'image une valeur correspondante à la quantité de lumière renvoyée. Cette valeur peut être comprise par exemple entre 0 et 255. Chaque pixel n'est donc plus représenté par un bit, mais par un octet. Pour cela, il faut que le matériel utilisé pour afficher l'image soit capable de produire les différents niveaux de gris correspondant.

Le nombre de niveaux de gris dépend du nombre de bits utilisés pour décrire la " couleur " de chaque pixel de l'image. Plus ce nombre est important, plus les niveaux possibles sont nombreux.

➤ **Images en couleurs**

Même s'il est parfois utile de pouvoir représenter des images en noir et blanc, les applications multimédias utilisent le plus souvent des images en couleurs. La représentation des couleurs s'effectue de la même manière que les images monochromes avec cependant quelques particularités. En effet, il faut tout d'abord choisir un modèle de représentation. On peut représenter les couleurs à l'aide de leurs composantes primaires. Les systèmes émettant de la lumière (écrans d'ordinateurs,...)

sont basés sur le principe de la synthèse additive : les couleurs sont composées d'un mélange de rouge, vert et bleu (modèle R.V.B.).

I.3.3 Les capteurs [2]

Le capteur d'images est un semi conducteur qui convertit la lumière en tension électrique en fonction du degré de luminosité. Ce capteur est constitué de matrice de cellules sensibles appelées photodiodes qui effectuent cette transformation tension- luminosité.

Pour acquérir des images en couleurs, les photodiodes sont associées à des filtres rouges, verts et bleus (RVB), chacune de ces couleurs étant échantillonnées sur 256 niveaux de luminosité (256^3). On distingue :

- les capteurs chimiques : systèmes biologique (œil)
- les films photographiques
- les capteurs photoélectriques (photo-diodes, CCD : Charged Coupled Device ou Dispositif à Transfert de Charge)
- les appareils numériques

D'autres capteurs existent tels que :

- IRM en imagerie médicale.
- imagerie sismique

Le signal obtenu est caractérisé par sa dimension et sa nature :

- 1D : image linéique (oscilloscope, barrette CCD, ...), une seule ligne
- 2D : est une image, souvent plane, de nature :
 - analogique : continue
 - numérique : discrète

La figure (Fig.I.2) montre un exemple de capteurs, Capteur CCD à matrice CCD (Charged Coupled Devices)

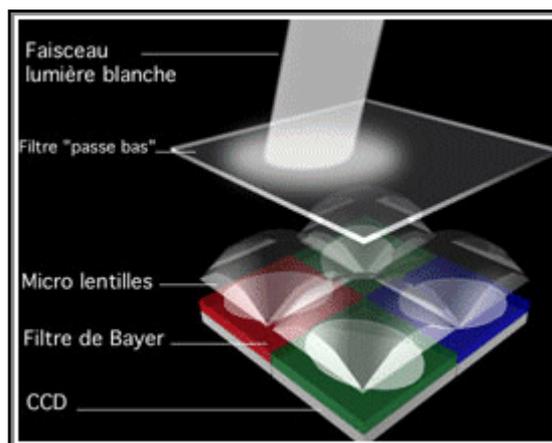


Fig.I.2- Capteur CCD (Charged Coupled Devices)

I.3.4 Notions d'échantillonnage et de quantification [2]

➤ Échantillonnage

L'échantillonnage consiste à remplacer une fonction continue dans le temps ou dans l'espace par une suite de 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, 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 à chaque zone rectangulaire $R(x, y)$ d'une image continue une unique valeur $I(x, y)$. On parle de sous-échantillonnage lorsque l'image est déjà discrétisée et qu'on diminue le nombre d'échantillons. Sous ces deux principes, on dit qu'une image est numérique, si elle est échantillonnée et quantifiée.

➤ 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, ou bien, c'est de coder les valeurs réelles de chaque échantillon en valeurs entières de manière optimale.

Le principe consiste à remplacer toute valeur située entre 2 niveaux de décision consécutifs d_i et d_{i+1} compris dans un intervalle $[m, M]$ par un niveau de reconstruction r_i où $[m, M]$ représente la gamme dynamique du signal quantifier.

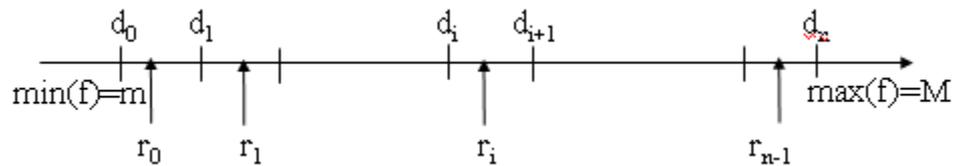


Fig.I.3- L'axe de niveaux de reconstruction

La quantification doit respecter la contrainte suivante : l'image quantifiée doit ressembler le plus possible à l'image réelle.

Pour évaluer la qualité de la quantification, on mesure l'erreur entre ces deux images (erreur de quantification).

Soient f et g , telles que f est l'intensité de l'image réelle et g : l'intensité de l'image quantifiée. On suppose que les valeurs de f suivent une variable aléatoire de densité $p(f)$. L'erreur (erreur quadratique moyenne) est donnée par :

$$\varepsilon = E\{(f - g)^2\} = \int_m^M (f - g)^2 p(f) df = \sum_{i=0}^{n-1} \int_{d_i}^{d_{i+1}} (f - r_i)^2 p(f) df$$

Pour trouver les positions optimales des d_i et des r_i on doit annuler les dérivées $\frac{\partial \varepsilon}{\partial d_i}$ et $\frac{\partial \varepsilon}{\partial r_i}$ telles que :

$$\frac{\partial \varepsilon}{\partial d_i} = (d_i - r_i)^2 p(d_i) - (d_i - r_{i-1})^2 p(d_i) = 0$$

$$\frac{\partial \varepsilon}{\partial r_i} = \int_{d_i}^{d_{i+1}} (d_i - r_i)^2 p(f) df = 0 ; \text{ pour } i = 1, \dots, n ;$$

Les solutions sont données par les relations suivantes :

$$r_i = 2d_i - r_{i-1}$$

$$r_i = \frac{\int_{d_i}^{d_{i+1}} f p(f) df}{\int_{d_i}^{d_{i+1}} p(f) df}$$

I.3.5 Numérisation (discrétisation) de l'image

La représentation informatique d'une image est nécessairement discrète. Le signal 2-D (deux dimensions) analogique est numérisé par :

- une discrétisation de l'espace : échantillonnage
- une discrétisation de la couleur : quantification
- L'opération d'échantillonnage exige un pavage de l'espace qui est motivé par :
 - L'adéquation au système d'acquisition
 - Des relations géométriques ou topologiques telles que le voisinage

Quelques exemples de pavage sont représentés sur la figure ci-dessous.

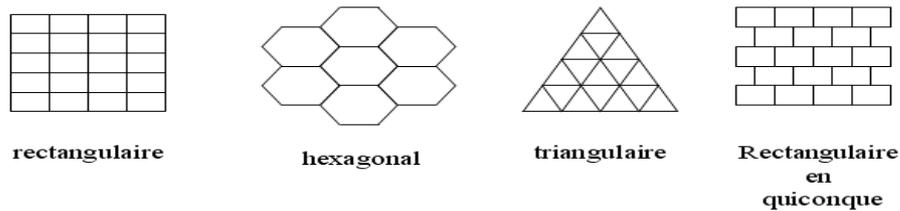


Fig.I.4- Les différents pavages

➤ **Le voisinage d'un pixel :**

Selon le type de pavage, on distingue de différents voisinages qui sont définis par le nombre de pixels voisins à un pixel donné. (Fig.I.5)

– pavage rectangulaire :



– pavage hexagonal :

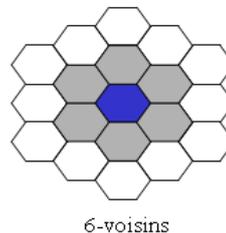


Fig.I.5- Les voisinages d'un pixel

➤ **Le codage binaire d'une image**

Pour une image en niveaux de gris, si l'on code les niveaux sur 8 bits, on pourra décrire $2^8=256$ valeurs entières. Pour une image couleur à k composantes, et si chaque composante est codée sur 8 bits, on aura 256^k au total.

I.3.6 Acquisition des données images [3]

L'acquisition d'images constitue un des maillons essentiels de toute chaîne de conception et de production d'images. Pour pouvoir manipuler une image sur un système informatique, il est avant

tout nécessaire de lui faire subir une transformation qui la rendra lisible et manipulable par ce système. Le passage de cet objet externe (l'image d'origine) à sa représentation interne (dans l'unité de traitement) se fait grâce à une procédure de numérisation. Ces systèmes de saisie, dénommés optiques, peuvent être classés en deux catégories principales : les caméras numériques et les scanners. A ce niveau, notons que le principe utilisé par le scanner est de plus en plus adapté aux domaines professionnels utilisant le traitement de l'image comme la télédétection, les arts graphiques, la médecine, etc.

Le développement technologique a permis l'apparition de nouveaux périphériques d'acquisition appelés cartes d'acquisition, qui fonctionnent à l'instar des caméras vidéo, grâce à un capteur C.C.D. La carte d'acquisition reçoit les images de la camera, de la T.V. ou du scanner afin de les convertir en informations binaires qui seront stockées dans un fichier.

La figure (Fig.I.6) montre un schéma de l'acquisition d'une image.

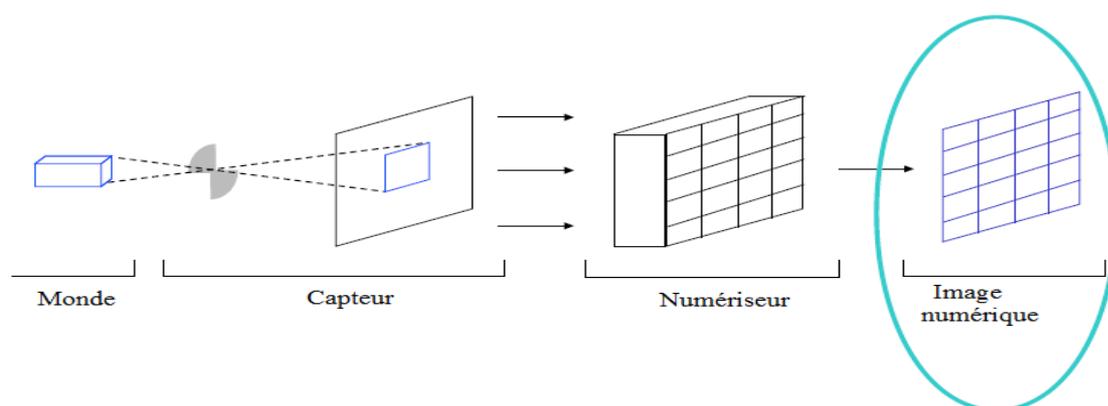


Fig.I.6- L'acquisition d'une image

I.4 Opérateurs de traitement d'images [4]

Par analogie avec les opérateurs mathématiques, les opérateurs de traitement d'images sont des opérateurs de traitement plus ou moins complexes, prenant en entrée une image et en produisant une image en sortie. On classe généralement les opérateurs en différentes familles, en fonction des informations qu'ils acceptent en entrée et qu'ils fournissent en sortie, et en fonction des transformations qu'ils font subir aux données. Ainsi, par exemple, on distingue :

➤ Opérateurs image→image

Parmi ces opérateurs, on peut citer :

- Opérateurs de modifications pixel à pixel (opérateurs point à point) : qui font le changement de la dynamique de l'image, opérateurs binaires pixel à pixel (et, ou, xor, etc.).

- Opérateurs locaux (traitent les pixels en fonction de leur voisinage) : opérateurs de flou, opérateurs morphologiques (érosion, dilatation, squelette), opérateurs de détection de contours.

- Opérateurs dans l'espace fréquentiel : opérateurs de réduction du bruit, filtres passe-bande (souvent utilisés en première approche pour améliorer l'image, on les appelle alors des opérateurs de pré-traitement).

- Opérateurs globaux : calcul des distances.

➤ **Opérateurs image → ensemble d'informations**

- Opérateurs de segmentation en frontières, en régions ;

- Opérateurs de classification de pixels ;

- Opérateurs de calcul de paramètres ;

➤ **Opérateurs ensemble d'informations → image**

Ce sont des constructeurs d'image à partir d'une carte de régions ou d'une liste de frontières (synthèse d'images).

I.4.1 Prétraitement [5]

Les images acquises ne peuvent échapper aux effets de dégradations dûs essentiellement aux phénomènes physiques tels que :

- La diffraction (déviations) du système optique.
- Le flou dû au mouvement de l'image durant son acquisition.

Pour pallier à ces dégradations on utilise en général le filtrage.

➤ **Filtres linéaires**

Un filtre linéaire transforme un ensemble de données d'entrée en un ensemble de données de sortie selon une opération mathématique appelée convolution. Lorsqu'il s'agit de données numérisées comme dans le cas du traitement d'image, la relation entre les valeurs des pixels de sortie et celle des pixels d'entrée est décrite par un tableau de nombres, généralement carré, appelé matrice de convolution. Le temps de calcul est souvent réduit lorsqu'on veut séparer un filtre en deux filtres dont la convolution mutuelle permet de le reconstituer. Cette remarque est utilisée en particulier pour créer

un filtre à deux dimensions à partir de deux filtres à une seule dimension (vecteurs) dans le sens horizontal et le sens vertical.

➤ Lissage

Ceux-ci sont des filtres passe-bas qui coupent plus ou moins les plus hautes fréquences. Ils sont utilisés pour atténuer les bruits d'origines les plus diverses qui polluent l'information, en particulier dans la détection de contours considérée ci-après. Techniquement, il s'agit de traductions discrètes de filtres continus qui comme ceux-ci, ne modifient pas le niveau global du signal. Les termes de la matrice de convolution sont donc généralement des entiers à diviser par leur somme.

- Filtre uniforme : Il est obtenu par convolution de deux filtres unidimensionnels rectangulaires. Toutes les composantes de la matrice ont la même valeur. L'imperfection de ce filtre réside dans le fait qu'il introduit des déphasages.
- Filtre pyramidal : La convolution d'un filtre rectangulaire avec lui-même conduit à un filtre triangulaire grâce auquel les phases ne sont plus modifiées. Le filtre pyramidal est obtenu à partir de filtres triangulaires dans les deux directions.
- Filtre gaussien : Ce filtre très populaire utilise la loi de probabilité de Gauss (voir Loi normale multidimensionnelle). Des approximations de plus en plus précises peuvent être obtenues, selon le Théorème de la limite centrale par itération de l'un des filtres précédents.

Le filtre gaussien est utilisé comme constituant du masque flou qui améliore la netteté apparente des photographies numériques. Bien qu'il soit popularisé par la photographie plus ou moins artistique, il est également utilisé dans certaines techniques, comme l'astronomie.

➤ Modification de l'histogramme [2]

L'histogramme des niveaux de gris nous informe sur la concentration de l'image, pour une image couleur, il y a un histogramme par composante. Il peut être normalisé pour donner une estimation de la densité de probabilité des pixels :

$$p(i) = \frac{hist(i)}{\sum_j hist(j)} \quad \text{avec} \quad \sum_i p(i) = 1$$

hist(i) représente la fréquence d'apparition du niveau de gris i

La fonction de répartition H est l'histogramme cumulé donnant la probabilité d'obtenir un niveau de gris inférieur ou égal à la taille de l'image.

- **Recadrage de l'histogramme**

Quand les valeurs de l'histogramme varient dans l'intervalle $[a, b]$, toutes les couleurs ne sont pas représentées. La transformation T qui permet d'étaler les valeurs dans l'intervalle $[0, N-1]$ s'appelle recadrage (Fig.I.7).

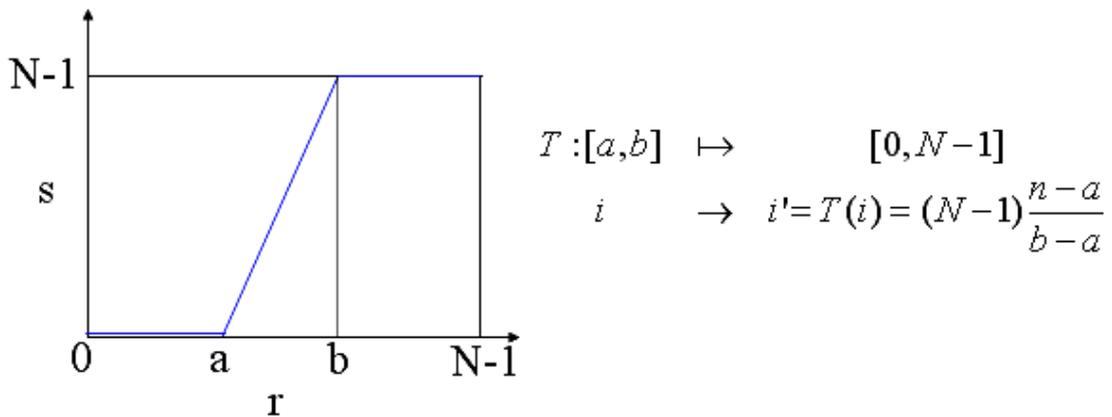


Fig.I.7- Recadrage de l'histogramme

- **Égalisation de l'histogramme**

Dans une image, il peut y avoir une majorité de pixels ayant une valeur inférieure (ou supérieure) à la luminance moyenne.

Une modification d'histogramme très répandue pour augmenter le contraste de manière automatique est la linéarisation d'histogramme. Le principe est de transformer l'image de manière à obtenir un histogramme plat, soit une distribution uniforme des intensités. Cela revient à maximiser l'entropie de l'image et donc à obtenir théoriquement une image présentant une information maximale.

La transformation T est monotone (souvent croissante) sur l'intervalle. Cette condition assurant que l'ordre des N intensités est préservé après la transformation. $0 \leq T(i) \leq N - 1$ pour $0 \leq i \leq N - 1$ garantit que la nouvelle image est cohérente avec les niveaux d'intensité autorisés.

On suppose que les valeurs de l'image $f(i, j)$ suivent une variable aléatoire de fonction de densité de probabilité $P_f(f)$ estimée par l'histogramme de l'image $p_f^*(f)$ définie par :

$$p_f^*(f) = \frac{n_k}{n}$$

Où n est le nombre total de pixel.

Soit $g = T(f)$ L'image transformée (T : non linéaire) et $P_g(g)$ la fonction de densité de probabilité de g uniforme donnée par $P_g(g) = \frac{1}{N-1}$, doit vérifier l'équation $P_g(g) = P_f(r) \frac{dr}{dg}$ donc $P_g(r) \frac{dT(r)}{dr} = P_f(r)$

Pour une image majoritairement claire la linéarisation va augmenter la dynamique de la partie sombre de l'histogramme au détriment de la partie claire. A noter que dans le cas discret, et du fait que l'histogramme soit une approximation d'une fonction de densité de probabilité, l'histogramme résultant est très rarement parfaitement plat.

I.4.2 Segmentation

Elle consiste à répartir l'ensemble des pixels de l'image en différents groupes. Chaque groupe est supposé correspondre à un "objet" de l'image. Quand il s'agit de séparer les pixels en 2 groupes, on parle alors de binarisation. Il existe une multitude méthodes de segmentation d'images, le choix de l'une d'elles dépend très fortement du type d'images et de l'application visée.

Le but de la segmentation est d'extraire (séparer) les entités d'une image pour y appliquer un traitement spécifique ou pour interpréter le contenu de l'image.

I.4.2.1 Méthodes de segmentation

Il existe une très grande diversité de techniques de segmentation que l'on peut classer selon trois approches : approche région, approche contour et approche hybride.

La première approche cherche à extraire les régions homogènes de l'image, alors que la deuxième approche cherche à extraire les frontières des régions homogènes, tandis que la troisième approche combine les deux approches précédentes.

I.4.2.1.1 Approche contours [6]

L'approche contour se caractérise par le fait qu'elle ne prend en compte que des informations sur le contour des objets. Les premiers modèles de segmentation s'appuient sur des détections de changement rapide d'intensité lumineuse ou de couleur, c'est-à-dire les contours de l'image. L'application de détecteurs de contours sous la forme de filtres dérivateurs permet d'obtenir les contours des objets présents dans la scène. Nous pouvons citer les approches se basant sur les différences finies comme l'opérateur de gradient, l'opérateur laplacien, les filtres de Sobel, Prewitt, Roberts ou bien des approches reposant sur des critères d'optimalité comme les filtres de Canny-

Deriche. Mais ce genre de techniques est peu exploitable car elles donnent des contours non fermés, bruités ou des contours non détectés.

Ainsi, considérer uniquement les contours pour extraire des objets d'intérêt n'est pas toujours satisfaisant, et prendre en compte les propriétés des régions comprises entre ces contours pourrait améliorer les approches basées uniquement sur les contours.

a)- Définition d'un contour actif [7]

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 ci-dessous.



Fig I.8- 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 elle-même.

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 actifs tout en gérant le problème de changement de topologie, de plus son extension aux dimensions supérieures est aisée. Le principe de cette méthode est le suivant :

L'évolution d'une courbe paramétrique fermée $C(p)$ est effectuée suivant une équation du type

$$\frac{\partial C}{\partial t} = FN \quad \text{ou } t \text{ est le temps, } F \text{ est la vitesse d'évolution et } N \text{ est la normale unitaire à la courbe.}$$

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 :

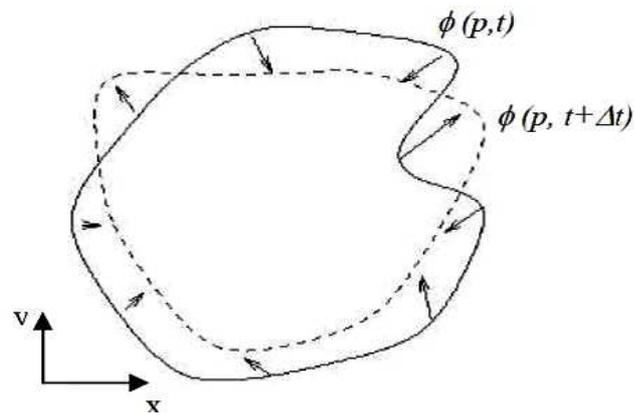


Fig I.9- Formulation des contours actifs par les ensembles de niveau zéro (Level Sets).

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 être fusionnées et devenir une seule courbe.

I.4.2.1.2 Approche région

Elle contient plusieurs techniques :

I.4.2.1.2.1 Segmentation par croissance de région

Elle permet de sélectionner un pixel ou un ensemble de pixels de l'image, appelé noyau, autour duquel on fait croître 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.4.2.1.2.2 Segmentation par division-fusion

Dans cette catégorie de segmentation trois grandes familles de méthodes sont distinguées :

a)- Méthodes par division

Cette méthode consiste à diviser l'image, qui constitue la région initiale, en région de plus en plus homogène. 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)- Méthodes 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 vérifié. 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)- Méthodes de 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 opérations sont répétées jusqu'à ce qu'elles ne soient plus possibles.

I.4.2.1.2.3 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 un cas particulier simple de 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 méthodes 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 pixel 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 ($C_1 \dots C_c$) par un ou plusieurs experts. Chaque classe C_i se voit donc affecter un ensemble d'apprentissage E_i , 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. 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 initialement choisi. Plusieurs méthodes de classification non supervisées ont été développées. La plus populaire est l'algorithme K-means et sa version floue FCM (Fuzzy C-means) qui sera présentée dans le troisième chapitre.

I.4.2.1.3 Approche hybride

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 représentations 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 oeuvre 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.4.2.1.4 Seuillage

Le seuillage est une méthode simple et très populaire qui permet d'extraire les objets du fond de l'image. Il constitue un cas particulier de la segmentation par classification non supervisée car elle consiste à affecter chaque pixel à la classe « fond » ou à la classe « objet ».

Le principe de base du seuillage consiste à chercher un niveau de gris appelé seuil, avec lequel le niveau de gris de chaque pixel est comparé de telle manière que :

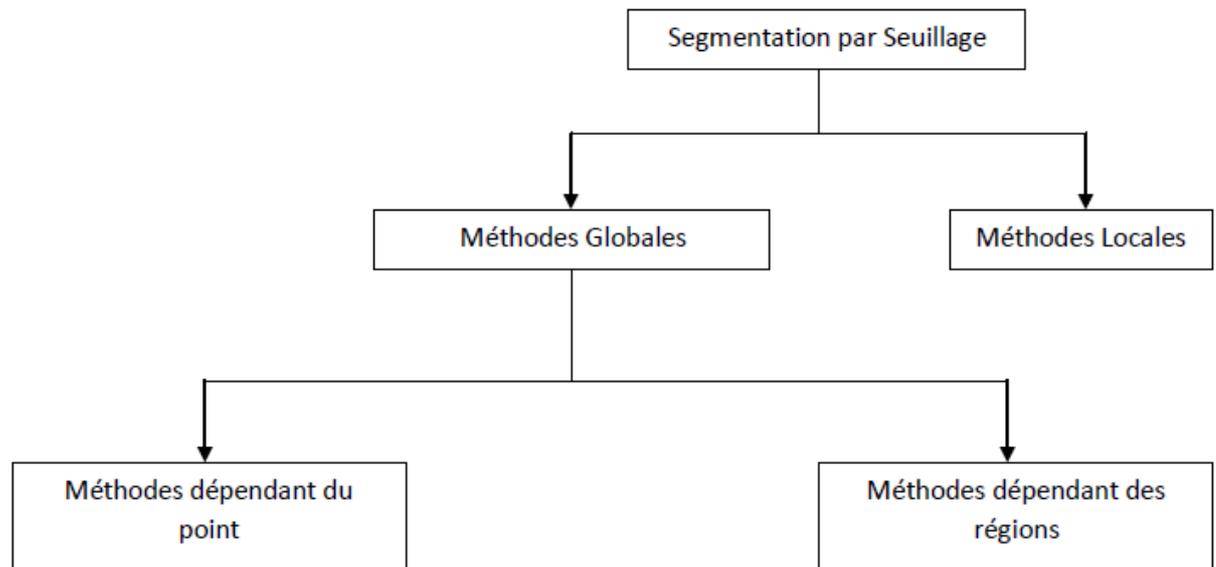
- Si la valeur du pixel $>$ seuil alors valeur du pixel = 1 ;
- Si la valeur du pixel $<$ seuil alors valeur du pixel = 0 ;

Le résultat du seuillage est une image binaire constituée de pixel noir ou blanc.

Le seuillage peut être :

- Global : un seuil pour toute l'image
- Local : un seuil pour une portion de l'image

La figure (fig. I.10) montre une taxinomie de quelques méthodes de seuillage. Nous allons nous intéresser qu'aux méthodes globales



- | | |
|--|---|
| -Méthodes basées sur l'analyse des concavités | -Méthodes basées sur la matrice de co-occurrence |
| -Méthodes basées sur la transformation d'histogramme | -Méthodes de matrice de transition |
| -Méthodes basées sur la théorie de l'information | -Méthodes basées sur la relaxation |
| -Méthodes préservant les moments | -Méthodes de relaxation par le gradient |
| -Méthodes basées sur l'analyse discriminante | -Méthodes multi-résolution |
| -Méthodes minimisant l'erreur quadratique | -Méthodes basées sur la théorie des ensembles flous |

Fig I.10- Organigramme des différentes techniques de seuillage.

Les méthodes de seuillage globales consistent généralement 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 quelques méthodes dépendant du point.

Ces méthodes utilisent généralement l'histogramme de l'image. A chaque élément (point de coordonnées (i, j)) de l'image I composée de $M \times N$ éléments correspond un niveau d'intensité lumineuse $I(i, j)$ (appelé niveau de gris) appartenant à l'ensemble $G = \{0, \dots, g, N_G\}$ 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 (g compris entre 0 et $N_G - 1$) le nombre de pixels de l'image $h(g)$ qui possèdent cette intensité lumineuse.

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 l'image 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.11).

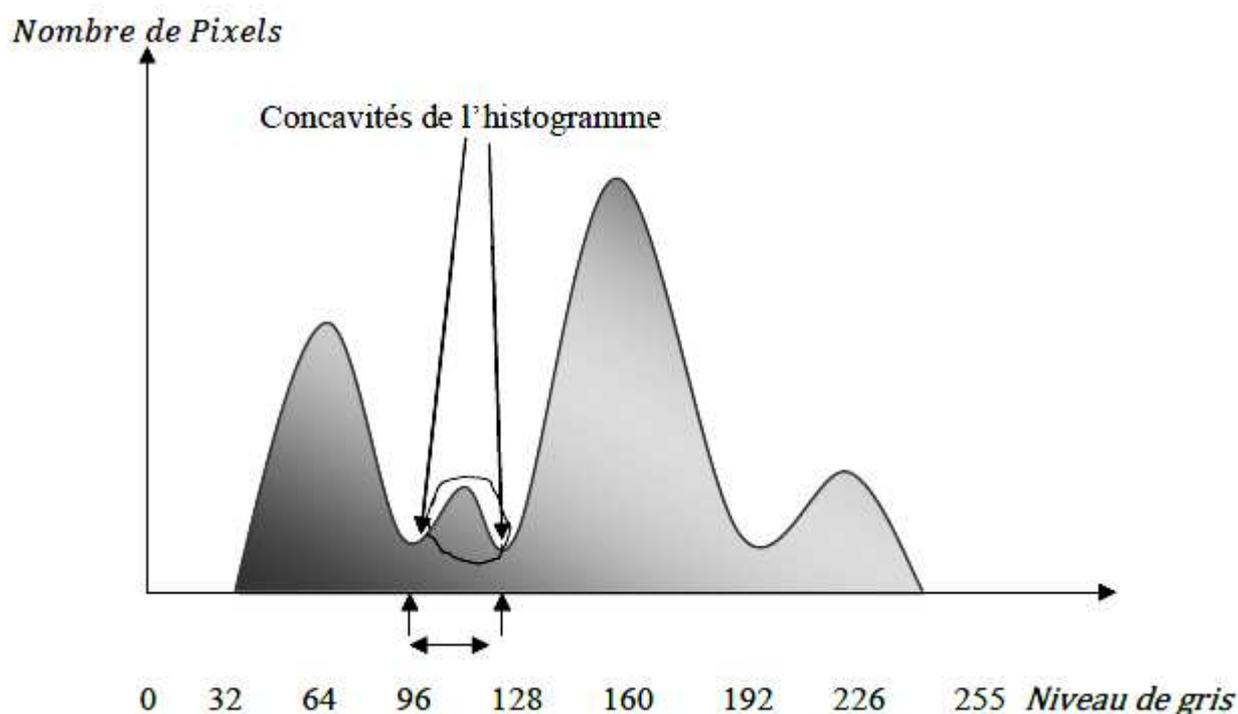


Fig I.11- Délimitation des classes par les vallées de l'histogramme.

Nous allons à présent présenter quelques méthodes de seuillage.

I.5 Méthodes de seuillage

I.5.1 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. [8].

Dans [9], 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 l'image 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 :

$$CM(s) = \frac{C(s)}{N(s)}$$

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

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

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 :

$$P(g_i, g_j, s) = \begin{cases} 1 & \text{si } g_i \leq s \leq g_j \\ 0 & \text{sinon} \end{cases}$$

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

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

$$c(g_i, g_j, s) = \begin{cases} \min(s - g_i, g_j - s) & \text{si } g_i \leq s \leq g_j \\ 0 & \text{sinon} \end{cases}$$

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

La valeur optimale du seuil $s^* = s$ et tel que :

$$CM(s^*) = \max_{s=1,2,\dots,N_G-1} CM(s)$$

I.5.2 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 [10], d'autres tiennent compte de la distribution spatiale des niveaux de gris de l'image en introduisant des entropies d'ordres supérieurs [11]. Parmi ces méthodes, la plus populaire est celle proposée par Kapur et al [10].

- **Méthode de Kapur**

Dans ce cas, la distribution de probabilité de l'objet P_t et la distribution de probabilité du fond $(1 - P_t)$ sont prises en compte en déterminant l'entropie de la partition.

$$S_{opt} = \max_t (H_{objet} + H_{fond}) = \max_t \left(- \sum_{i=0}^t \frac{p_i}{P_t} \log \frac{p_i}{P_t} \right) - \left(\sum_{i=t+1}^{L-1} \frac{p_i}{1 - P_t} \log \frac{p_i}{1 - P_t} \right)$$

Où $P_t = \sum_{i=0}^t p_i$

I.5.3 Méthode d'Otsu

Elle constitue une méthode de référence dans le domaine du seuillage [12]. Elle est 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 Ω_f (fond ou foreground) et Ω_b (objet ou background) les relations suivantes permettent de déterminer le seuil s de séparation entre Ω_f et Ω_b .

Soit p_i la probabilité d'occurrence (apparition) de niveau de gris g_i , $i = 0, 1, \dots, N_G - 1$. Soient m et σ respectivement la valeur moyenne et l'écart type des intensités de l'image.

Les probabilités qu'un point appartienne à Ω_f ou Ω_b sont données respectivement par :

$$P_s \text{ et } 1 - P_s$$

P_s : est la probabilité d'appartenance d'un pixel à la classe Ω_b .

Les valeurs moyennes des intensités calculées dans Ω_f et Ω_b sont données par :

$$m_T = \sum_{i=0}^s ip_i \text{ et } 1 - m_T$$

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

- Les centres des classes :

$$m_b = \frac{m_T}{P_s} \text{ et } m_f = \frac{1 - m_T}{1 - P_s}$$

- La variance qui sépare les deux classes Ω_f de Ω_b est :

$$\sigma_B^2(s^*) = P_s(m_b - m_T)^2 + (1 - P_s)(m_f - m_T)^2$$

Le seuil s^* qui maximise la variance interclasses est alors fourni par la relation :

$$\sigma_B^2(s^*) = \max_{s=1,2,\dots,N_G-1} \{\sigma_B^2(s)\}$$

I.6 Conclusion

Nous avons décrit dans ce chapitre d'une manière succincte quelques notions du traitement d'images. L'image véhicule des informations très riches et complexes dont la manipulation, le stockage et la représentation de son contenu se heurtent à certaines limitations.

Grâce au traitement d'image, ces contraintes sont levées ou contournées. En effet, ce domaine cherche à détecter la présence de certaines formes, certains contours ou certaines textures d'un modèle connu, c'est le problème de détection.

Un autre aspect de traitement d'image concerne l'analyse et la compréhension de l'image dans le but d'en extraire des informations utiles. Il cherche aussi parfois à comprimer l'image, afin de gagner en vitesse lors de la transmission de l'information, et en capacité de stockage, tout en dégradant le moins possible les images considérées.

La plus part des applications basées sur le traitement d'images font appel à l'opération de segmentation ou plus précisément à celle du seuillage afin d'identifier les objets que contient l'image.

Et c'est justement, à ce type d'opération que notre étude s'est portée et sera détaillée dans les chapitres qui suivent.

CHAPITRE II

La Logique Floue

En

Traitement d'image

II.1 Introduction

La logique floue, ou plus généralement le traitement des incertitudes, a pour objet d'étude la représentation des connaissances imprécises et le raisonnement approché. On peut donc la situer à côté des heuristiques de résolution de problèmes, des systèmes experts, de l'apprentissage, de l'intelligence artificielle distribuée et même du traitement de la langue naturelle, domaines qui composent les techniques d'intelligence artificielle au sein des sciences cognitives.

La logique floue a été introduite en 1995 par Lotfi A.ZADEH, pour répondre aux problèmes auxquels sont confrontés de nombreux systèmes complexes qui doivent traiter des informations qui sont de nature imparfaite.

On distingue principalement deux types d'imperfection :

- Les incertitudes qui ont trait à la véracité de l'information, c'est-à-dire à sa conformité à une réalité.
- Les imprécisions concernent davantage le contenu de l'information. Une information est vraie à un certain degré.

Face à ces imperfections liées très souvent à la perception du monde réel, Zadeh a introduit les deux théories suivantes :

- La théorie des sous ensembles flous pour modéliser l'imprécision en s'approchant notamment du raisonnement humain, robuste face à une appréciation imprécise de nature plutôt quantitative.
- La théorie des possibilités, formalisée et étendue notamment par Dubois et Prade, pour gérer l'incertitude d'évènements de nature non probabiliste qui peuvent être précis ou imprécis.

La théorie des possibilités et la théorie des sous-ensembles flous constituent le cadre de base de la logique floue. Dans notre étude, nous nous appuyons essentiellement sur la capacité de la logique floue à gérer l'imprécision de connaissances de nature à la fois qualitative et « numérique ».

La logique floue peut être également définie comme une branche de la logique classique, utilisant le degré d'appartenance dans les ensembles au lieu de l'appartenance stricte notée par vrai ou faux ; autrement dit, c'est une extension de la logique classique qui concerne la définition des ensembles aux limites imprécises.

II.2 Concepts fondamentaux flous

Le concept d'ensemble flou a été introduit pour éviter le passage brusque d'une classe à une autre (par exemple, de la classe noire à la classe blanche) et autoriser des éléments à n'appartenir complètement ni à l'une ni à l'autre (par exemple gris), ou encore à appartenir partiellement à chacune (par exemple, avec un fort degré à la classe noire et un faible degré à la classe blanche comme c'est le cas du gris foncé). 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 opérateur expert ou obtenues par des instruments de mesure qui manquent de fidélité. [13]

II.2.1 Univers de discours

Soit U une collection connue ou discrète d'objets dénotés $\{x\}$, U est appelée univers de discours et x représente l'élément générique de U .

II.2.1.1 Sous-ensembles flous

Soit E un ensemble dénombrable ou non. Un sous-ensemble flou A de E est défini par une fonction d'appartenance μ_A à valeur dans $[0, 1]$ qui associe à chaque élément x de E un degré d'appartenance $\mu_A(x)$ indiquant le niveau d'appartenance de x à A . L'ensemble E est appelé ensemble ou univers de référence.

II.2.1.2 Fonction d'appartenance [14]

Comme son nom l'indique, une fonction d'appartenance permet de définir le degré d'appartenance d'un objet à un ensemble donné. Elle constitue l'un des paramètres de conception de la logique floue à savoir la définition d'un sous-ensemble flou sur un univers de discours.

➤ Exemple de fonction d'appartenance

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

- **Fonction d'appartenance trapézoïdale**

Elle est donnée par l'équation suivante :

$$\mu_A(x) = \begin{cases} 0 & \text{si } x \leq a - c \text{ ou } x \geq b + d \\ \frac{x}{c} + \left(1 - \frac{a}{c}\right) & \text{si } a - c < x < a \\ 1 & \text{si } a \leq x \leq b \\ -\frac{x}{d} + \left(1 + \frac{b}{d}\right) & \text{si } b < x < b + d \end{cases}$$

Sa courbe est donnée comme suit :

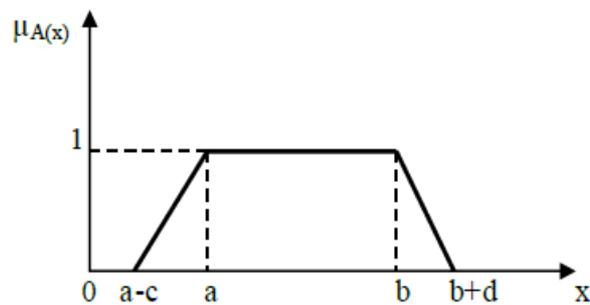


Fig.II.1- Fonction d'appartenance trapézoïdale.

Dans le cas où $a=b$ la fonction est dite triangulaire et sa courbe est représentée par la figure suivante :

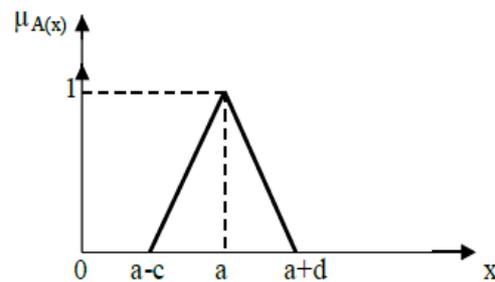


Fig.II.2- Fonction d'appartenance triangulaire.

- **Fonction d'appartenance exponentielle**

Elle est donnée par la relation suivante :

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

Sa courbe est donnée comme suit :

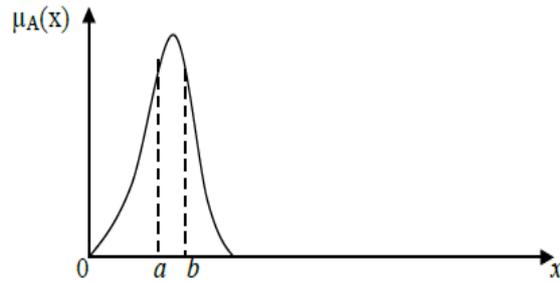


Fig.II.3- Fonction d'appartenance exponentielle.

- **Fonction d'appartenance gaussienne**

Elle est donnée sous la forme :

$$\mu(x, c, \sigma) = \exp\left(-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2\right)$$

Où c est le centre de la gaussienne et σ sa largeur.

Sa courbe est donnée comme suit :

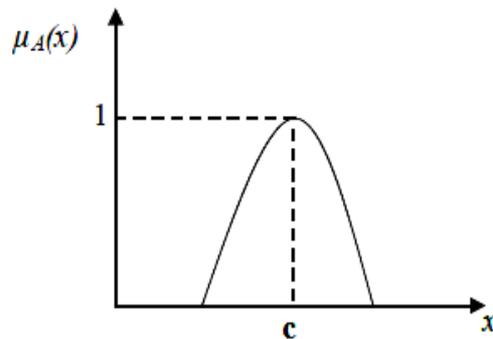


Fig.II.4- Fonction d'appartenance gaussienne.

- **Fonction d'appartenance singleton**

Cette fonction est représentée sous cette forme :

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

Sa courbe à la forme suivante :

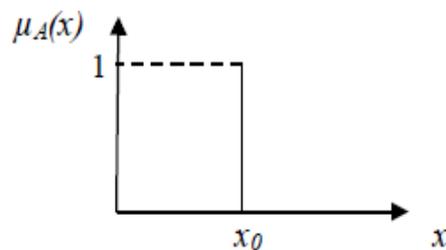


Fig.II.5- Fonction d'appartenance singleton.

II.2.1.3 Caractéristiques d'un sous-ensemble flou [15]

Nous allons définir, dans ce paragraphe, les caractéristiques les plus utiles à la représentation d'un sous-ensemble flou noté A et qui ont trait principalement à la forme de sa fonction d'appartenance μ_A .

- **Le support**

On appelle support de A , noté $supp(A)$, l'ensemble des éléments de E pour lesquels le degré d'appartenance à A n'est pas nul :

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

- **Le noyau**

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

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

- **Les α – coupes**

On appelle α -coupes de A , noté A_α , l'ensemble des éléments de E pour lesquels le degré d'appartenance à A est au moins égale à α :

$$A_\alpha = \{x \in E / \mu_A(x) \geq \alpha\}$$

Les α -coupes strictes (ou fortes) sont définies par :

$$A_\alpha = \{x \in E / \mu_A(x) > \alpha\}$$

II.2.1.4 Opérations de base sur les ensembles flous [15]

Le concept de sous-ensemble flou étant une généralisation du concept classique de sous-ensemble, il est légitime de généraliser les opérations ensemblistes classiques aux sous-ensembles.

Soient A et B deux sous-ensembles flous d'un même ensemble de référence E , on généralise alors les opérations ensemblistes sur A et B de la manière suivante:

- **Egalité**

A et B sont dits égaux si leurs fonctions d'appartenance prennent la même valeur pour l'élément de E :

$$A = B \Leftrightarrow x \in E, \mu_A(x) = \mu_B(x)$$

- **Inclusion**

On dit que A est inclus dans B si tout élément x de E appartient à B avec un degré au moins aussi grand que celui de son appartenance à A :

$$A \subseteq B \Leftrightarrow x \in E, \mu_A(x) \leq \mu_B(x)$$

- **Intersection**

L'intersection de deux sous-ensembles flous A et B de E est un sous-ensemble flou composé des éléments de E auxquels on attribue le plus petit des deux degrés d'appartenance à A et à B :

$$A \cap B \Leftrightarrow x \in E, \mu_C(x) = \min(\mu_A(x), \mu_B(x))$$

- **Union**

L'union de deux sous-ensembles flous A et B de E est un sous-ensemble flou composé des éléments de E auxquels on attribue le plus grand des deux degrés d'appartenance à A et à B :

$$A \cup B \Leftrightarrow x \in E, \mu_C(x) = \max(\mu_A(x), \mu_B(x))$$

- **Normes et conormes triangulaires**

La généralisation de l'union et de l'insertion ensembliste classique aux sous-ensembles flous n'est pas définie de manière unique. Zadeh a proposé, en premier, d'utiliser les opérateurs « min », pour l'intersection et « max » pour l'union de sous-ensembles flous.

Il existe, en fait, une multitude d'opérateurs que l'on peut utiliser pour mettre en œuvre les opérations d'union et d'intersection.

Ces opérateurs sont regroupés en deux familles. Les normes triangulaires, notées T-normes, qui définissent les opérateurs d'intersection ou de conjonction et les normes triangulaires, notées T-conormes, qui définissent les opérateurs d'union ou de disjonction.

- **T-normes**

$T : [0, 1] \times [0, 1] \rightarrow [0, 1]$ est une fonction de type T-norme si et seulement si pour chaque élément x, y et z de [0, 1], elle vérifie les propriétés suivantes :

$$(T1) : T(x, 1) = 1 \quad \text{existence d'un élément neutre 1}$$

$$(T2) : x \leq y, u \leq v \Rightarrow T(x, u) \leq T(y, v) \text{ isotonie}$$

$$\forall (A, B) \in C^2, A \cap B = \emptyset \Rightarrow f(A \cup B) = f(A) + f(B) + \lambda f(A) \times f(B)$$

Avec $\lambda > -1$

- Les mesures de possibilités ;

II.2.1.4.1 Produit cartésien et projection de sous-ensembles flous [17]

Les connaissances associées à un élément sont généralement déduites d'univers de référence différents qui permettent de caractériser cet élément de manière explicite.

Par exemple, dans le domaine de la classification, la caractérisation d'une classe se formalise souvent par rapport à plusieurs attributs, ou variables, définis dans différents espaces de référence ; on parle alors de vecteurs d'attributs.

Ainsi, si l'on veut travailler sur plusieurs ensembles de références simultanément, il faut construire un univers global. Pour ce faire, on effectue le produit cartésien des différents univers de référence.

Inversement, si l'on dispose de connaissances globales sur un univers complexe, il est intéressant d'en déduire des informations relatives aux différents univers de référence qui le composent. On réalise alors une projection de cet univers global sur chacun des univers de référence.

On définit alors, plus précisément, le produit cartésien et la projection de la manière suivante :

- **Le produit cartésien :**

Soient des sous-ensembles flous A_1, A_2, \dots, A_n respectivement définis sur X_1, X_2, \dots, X_n , on définit leur produit cartésien $A = A_1 \times A_2 \times \dots \times A_n$ comme un sous-ensemble flou de E de fonction d'appartenance :

$$\forall x = (x_1, x_2, \dots, x_n) \in E, \mu_A(x) = \min(\mu_{A_1}(x_1), \mu_{A_2}(x_2), \dots, \mu_{A_n}(x_n))$$

- **La projection**

La projection d'un sous-ensemble flou A de $E_1 \times E_2 \times \dots \times E_n$ sur $E_a \times E_b \times \dots \times E_m$ est un sous-ensemble flou $\text{proj}(A)$, défini sur $E_a \times E_b \times \dots \times E_m$ de fonction d'appartenance :

$$\begin{aligned} \forall x \in (E_a \times E_b \times \dots \times E_m), \mu_{\text{proj}(A)}(x) \\ = \sup_{\{i/1 \leq i \leq n, i \neq a, \dots, i \neq m\}} \mu_A(\dots, x_i, \dots) \end{aligned}$$

II.2.1.4.2 Géométrie floue [16]

Plusieurs concepts et propriétés géométriques issus de la théorie classique des ensembles ont été généralisés au cas flou. Soit un sous ensemble flou A qui est défini par sa fonction d'appartenance $\mu(x)$.

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

- **La surface**

La surface d'un sous ensemble flou A de fonction d'appartenance μ est définie par :

$$S(A) = \int \mu(x) dx$$

Où l'intégrale est calculée sur une région telle que $\mu \neq 0$. Lorsque μ est constant par morceaux. X forme une partition $X = \cup_i X_i$ telle que $\forall x \in X_i, \mu(x) = S_i$. Dans ce cas $\mu(x)$ est la somme des surfaces de ces morceaux (régions) où μ 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.

- **Le périmètre**

Le périmètre d'un sous ensemble flou A de fonction d'appartenance μ est défini par :

$$Pr(A) = \int |\nabla \mu(x)| dx$$

- **La compacité**

Dans un sous ensemble flou A ayant une surface $S(A)$ et un périmètre $Pr(A)$ la compacité est définie par:

$$Comp(A) = \frac{S(A)}{Pr^2(A)}$$

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

- **La hauteur et la largeur**

La hauteur et la largeur d'un sous ensemble flou A sont ses projections sur des lignes verticales et horizontales respectivement. Ce sont données comme suit :

$$H(A) = \int \left[\max_x \mu(x, y) \right] dy$$

$$L(A) = \int \left[\max_y \mu(x, y) \right] dx$$

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

- **Connexité dans les ensembles flous**

Les opérateurs ensemblistes 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 A , est défini comme suit :

$$C_A(P, Q) = \max_{L_{P,Q}} \left[\min_{1 \leq i \leq n} \mu(P_i) \right]$$

Où $L_{P,Q} = [P_i, \dots, P_n]$ est un chemin de $P = P_1$ à $Q = P_n$ dans X .

Nous disons que P et Q sont connectés dans μ si $C_A(P, Q) \geq \min \{\mu(P), \mu(Q)\}$.

La relation entre le coût de connexion Ψ_A et le degré de connexité C_A entre deux éléments P et Q de X est représentée par $\Psi_A = 1 - C_A$.

II.2.2 Variable linguistique [16]

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 prend 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.

➤ **Exemple de variable linguistique**

Considérons l'exemple de la taille d'un objet. En termes numériques, cette taille peut être exprimée par une valeur variant dans un domaine S (typiquement S est un sous-ensemble de \mathbb{R}^+). En termes linguistiques, la taille peut être exprimée par l'aide de quelques termes tels que très petit, petit, moyen, grand, très grand, etc. La sémantique de ces termes est définie par des ensembles flous sur S . La figure (Fig.II.5) illustre la notion de variable linguistique « taille ».

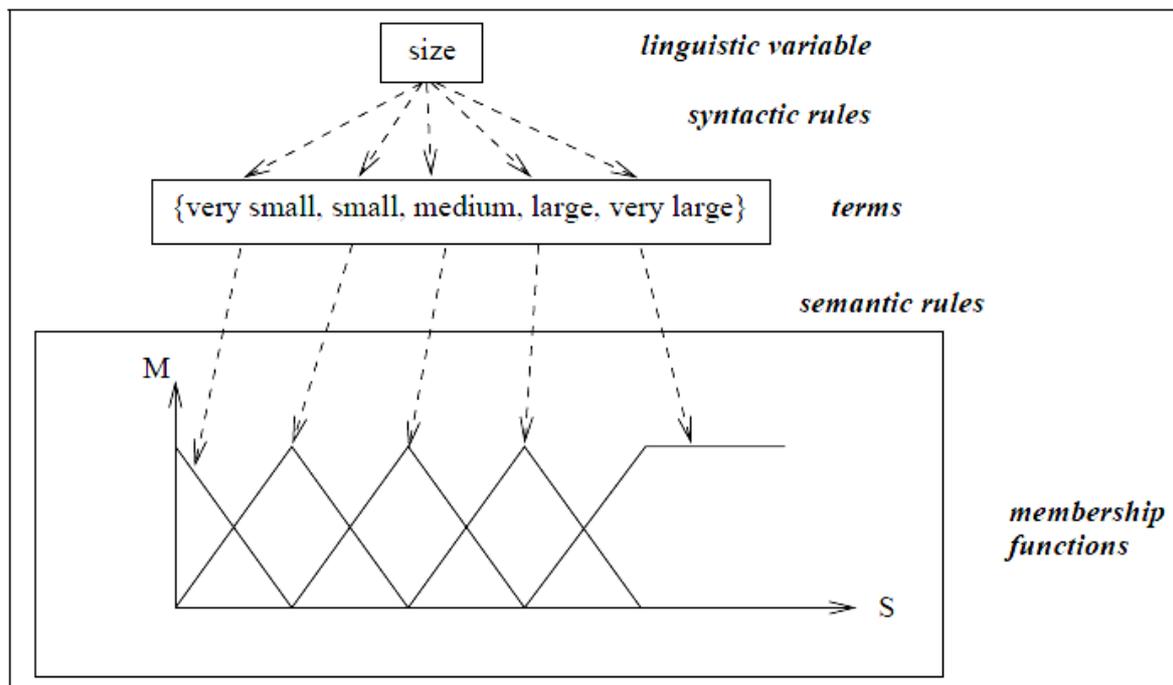


Fig.II.5- Illustration de la variable linguistique « taille », de ses termes et des ensembles flous associés. Les flèches allant de la variable linguistique à l'ensemble de termes représentent les règles syntaxiques. Le deuxième ensemble de flèches représente les règles sémantiques et traduit les termes en fonctions d'appartenance.

II.2.3 Les règles d'inférences

Les règles d'inférences constituent un système de règles floues permettant de décrire sous forme de règles linguistiques, les relations entre les variables d'entrée et celles de sortie d'un système donné.

La logique floue a pour objectif de formaliser et de mettre en œuvre la façon de raisonner d'un être humain. En cela, elle peut être classée dans le domaine de l'intelligence artificielle.

L'outil le plus utilisé dans les applications de logique floue est la base de règles floues. Une base de règles floues est composée de règles qui sont généralement utilisées en parallèle, mais peuvent également être enchaînées dans certaines applications.

Une règle est du type :

SI « prédicat » ALORS « conclusion ».

Par exemple : « Si température élevée et pression forte ALORS ventilation forte et soupape grande ouverte ».

Les bases de règles floues, tout comme les systèmes experts classiques, fonctionnent en s'appuyant sur une base de connaissance issue de l'expertise humaine. Il y a néanmoins de grandes différences dans les caractéristiques et le traitement de cette connaissance.

II.2.4 Structure interne d'un système d'inférence floue

Un système flou est un système à base de connaissances particulières, dont l'architecture de base illustrée par la figure ci-dessous, se compose essentiellement de quatre modules à savoir fuzzification, base des règles floues, raisonnement flou et défuzzification.

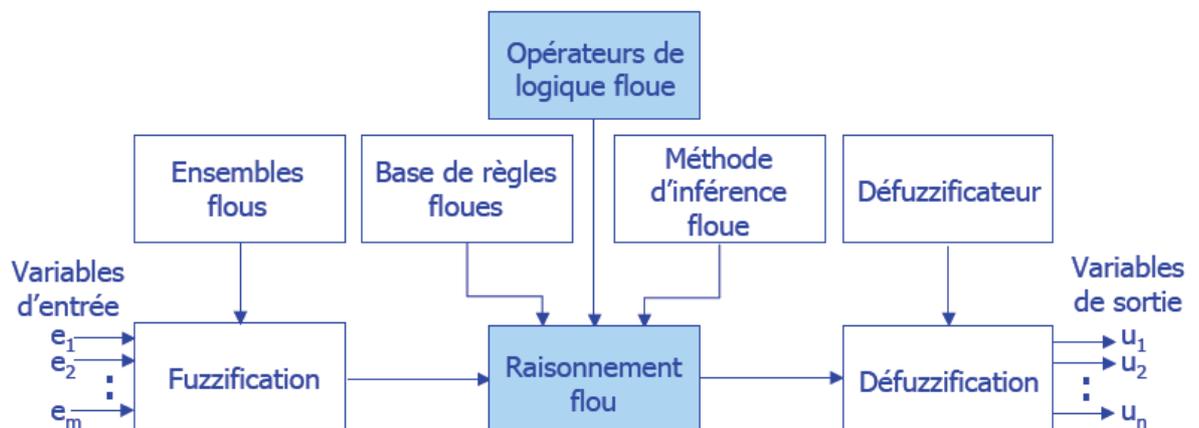


Fig.II.6- Architecture de base d'un système flou

II.2.5 Procédure de raisonnement flou

➤ Fuzzification

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

➤ **Base des règles floues**

C'est une base connaissance qui contient les règles floues décrivant le comportement du système.

L'ensemble des règles se présente comme suit :

Si condition 1 (**Et /Ou**) condition 2 (**Et /Ou**) ... Alors action sur les sorties.

- Les règles peuvent mettre en jeu plusieurs variables dans leurs conditions et leurs conclusions.
- Le contrôleur nécessite, en général, en entrée l'erreur et la dérivée de l'erreur.

➤ **Le raisonnement flou**

Il transforme à l'aide des opérateurs flous, la partie floue issue de fuzzification en une nouvelle partie floue conformément aux règles floues et la méthode d'inférence choisie (Mamdani ou Sugeno), l'agrégation des n règles s'effectuent en combinant les différentes règles floues par l'opérateur flou **OU**.

➤ **Défuzzification [18]**

C'est une interface « linguistique - numérique » qui transforme la partie floue issue du raisonnement flou en valeurs numériques directement exploitables par le processus. En sortie le système flou ne pas communiquer des valeurs floues qu'il peut seul exploiter. Il lui donc nécessaire de fournir des valeurs précises, c'est le rôle de la défuzzification. Cette étape s'effectue toujours à l'aide des fonctions d'appartenance. A partir des degrés d'appartenance, on obtient autant de valeurs qu'il y a d'états. Pour déterminer la valeur précise à utiliser, on peut soit conserver le maximum, soit calculer la moyenne pondérée, soit déterminer le centre de gravité des valeurs obtenues.

La méthode de défuzzification la plus utilisée est celle de la détermination du centre de gravité de la fonction d'appartenance résultante $\mu_{res}(z)$. Dans ce contexte, il suffit de calculer z^* . La figure (Fig.II.7) montre le principe de défuzzification.

avec

$$z^* = \frac{\int x\mu(x) dx}{\int \mu(x) dx}$$

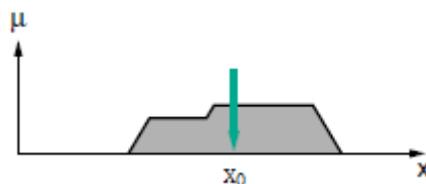


Fig.II.7- Défuzzification par centre de gravité.

II.3 Systèmes et modèles flous type-2 [19]

Un système flou est basé sur un ensemble de règles. Et pour construire une certaine règle, on utilise des connaissances incertaines. Cette incertitude mène alors à des règles dont les prémisses ou les conséquences sont incertaines, ce qui provoque l'incertitude des fonctions d'appartenance. Ces systèmes flous sont alors dits de type-1 dont les fonctions d'appartenance sont aussi dites ensembles flous type-1, sont incapables de prendre en compte de telles incertitudes de règles. Ainsi 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 a 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 fait 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 fournit 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 cette technique relativement nouvelle.

II.3.1 Concept des ensembles flous type-2

Le concept des ensembles flous type-2 a été introduit par Zadeh [20] 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 où nous avons de l'incertitude dans les valeurs d'appartenance elles-mêmes. L'incertitude peut être soit dans la forme de la fonctions 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 Types d'ensembles flous type-2

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

II.3.1.1.1 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.3.1.1.2 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 $[0, 1]$ [21]. 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.3.1.1.3 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.3.1.2 Représentation des ensembles flous type-2

Une fonction d'appartenance type-2 peut être vue comme une fonction à deux variables. Pour chaque x et le degré d'appartenance primaire μ_1 , nous avons une appartenance secondaire, qui est un nombre ordinaire noté μ_2 (Fig.III.8).

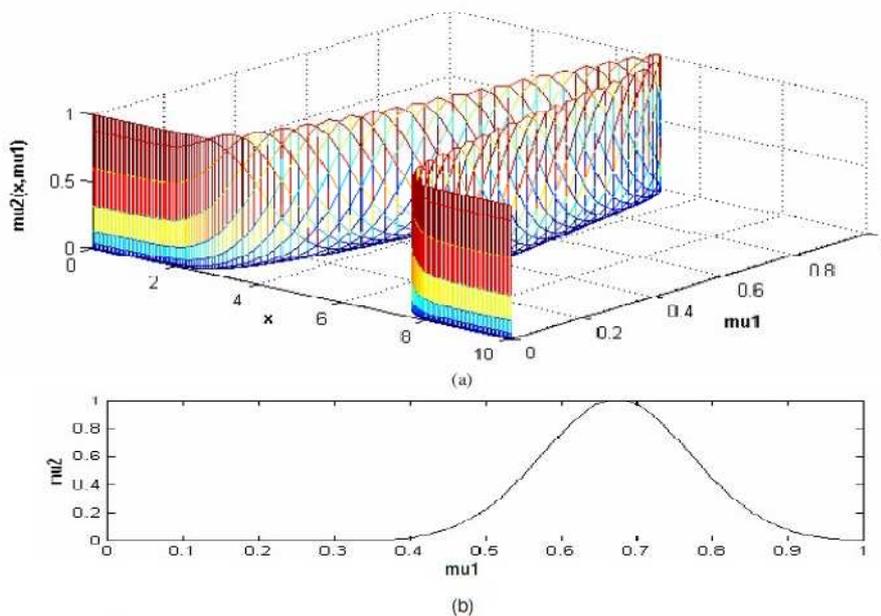


Fig.II.8- a/ Représentation tridimensionnelle d'un ensemble flou type-II Gaussien

b/ Degré d'appartenance flou correspondant a $x = 4.25$

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

$$\mu_2(x, \mu_1) : X \times [0, 1] \rightarrow [0, 1]$$

Où X est l'espace des entrées x . La figure (Fig.II.8.a) est une représentation tridimensionnelle d'un ensemble flou type-2 Gaussien, ayant une fonction d'appartenance principale Gaussienne, et la figure (Fig.II.8.b) représente le degré d'appartenance flou type Gaussien correspondant à $x = 4.25$.

II.3.2 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.

➤ Multiplication

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

$$F \times G = \int v \int w [f(v) * g(w)] / (v \times w) dv dw$$

Où $*$ indique la T-norme utilisée, c.-à-d., $F \times G = F \cap G$, par conséquent, T-norme produit sera utilisée pour multiplier deux ensembles flous.

➤ Addition

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

$$F + G = \int v \int w [f(v) * g(w)] / (v + w) dv dw$$

Lorsque F et G sont des ensembles flou type-1 intervalle, l'équation ci-dessus sera considérablement simplifiée à:

$$F + G = \int v \in F \int w \in G 1 * 1 / (v + w) dv dw$$

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 $lf + la$ et le plus grand terme étant $rf + rg$. Puisque F et G sont continus, alors $F + G$ est aussi continu, par conséquent, $F + G$ est un ensemble type-1 intervalle défini par le domaine L ($L = [lf + la, rf + rg]$) tel que :

$$F + G = \int_{v \in L} 1/v dv$$

D'une manière similaire, la somme de n ensembles type-1 intervalle F_1, \dots, F_n , ayant comme domaine $[l_1, r_1] \dots [l_n, r_n]$, respectivement, est un ensemble intervalle sur le domaine $[\sum_{i=1}^n l_i, \sum_{i=1}^n r_i]$.

II.3.3 Système flou type-2

La structure d'un système flou type-2 est représentée dans la figure (Fig.II.9) [22]. 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

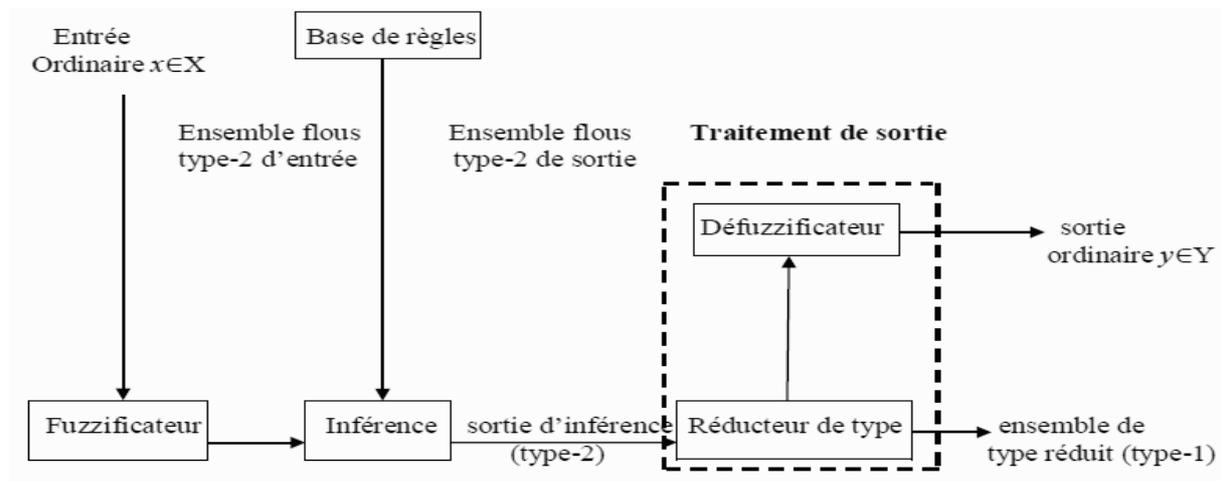


Fig.II.9- Structure d'un système flou type-2, avec ses deux sorties

II.3.3.1 Fuzzification

Dans cette étape seule la fuzzification singleton sera utilisée [23], en d'autres termes, l'entrée floue est un point singulier possédant une valeur d'appartenance unitaire.

II.3.3.2 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 $i^{\text{ème}}$ règle d'un système flou type-2 aura la forme. [24].

$R = S_i$ 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.3.3.3 Réduction de type

Remarquons dans la figure (Fig.II.9) 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.

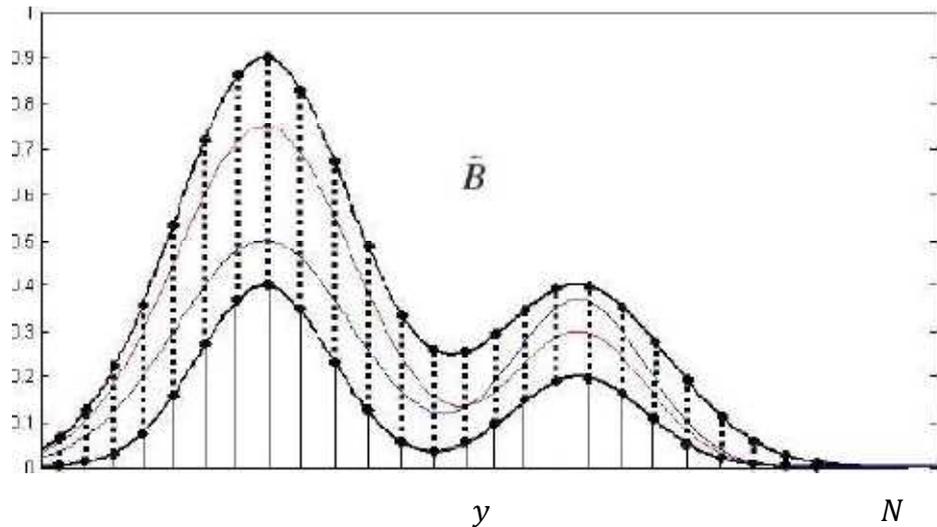


Fig.II.10- Discretisation d'un ensemble flou type-2 pour des raisons de réduction de type

Dans un système flou type-1, où les ensembles de sortie sont des ensembles flous type-1, nous effectuons la défuzzification dans le 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 appelée alors "Réduction de type" [21], 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.3.3.4 Déffuzification

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

II.4 Conclusion

Classée parmi les techniques de l'intelligence artificielle, la logique floue permet de modéliser puis de remplacer l'expertise de conduite de processus, expertise en provenance du concepteur ou de l'utilisateur. Outil d'amélioration de la qualité, de la productivité, elle procure des avantages concurrentiels à l'industriel en quête d'optimisation technico-économique.

Dans ce chapitre, on a bien présenté les règles et les propriétés de la logique floue, qui seront utilisées dans le prochain chapitre dédié au seuillage flou d'une image.

CHAPITRE III

Le seuillage flou

III. 1 Introduction

Le but de ce chapitre est de montrer comment la logique floue est introduite en segmentation d'image et plus particulièrement pour le seuillage flou de l'image.

III.2 Segmentation floue

La segmentation d'image est définie comme une partition de l'image en régions, qui sont des ensembles nets (par opposition aux ensembles flous). Il y a un choix univoque pour chaque pixel d'appartenir ou non à chaque région. Mais un pixel dans « le centre » d'une région homogène, appartient certainement beaucoup plus à cette région que des pixels agglomérés à la fin d'une croissance de régions par exemple. Et un pixel près d'un contour n'est certainement pas dans la même région qu'un pixel placé de l'autre côté de ce contour. C'est pourquoi on propose souvent de construire des régions qui sont des ensembles flous, avec pour chaque pixel de l'image un degré d'appartenance à chaque région.

Les degrés d'appartenance des pixels aux régions peuvent être calculés sur un double critère de proximité spatiale et de différence de gradient avec les germes des régions. Ils sont par exemple basés sur la « distance topographique » définie dans [25].

Soit Ω un référentiel fini (ensemble de N pixels). Une segmentation floue de Ω est un ensemble de M régions floues R_j dont les supports sont inclus dans Ω et vérifiant les deux axiomes suivants :

Si $\mu_j(s)$ est le degré d'appartenance du pixel s à la région R_j , alors :

$$1. \forall s \in \Omega, \forall j, \mu_j(s) \in [0,1]$$

$$2. \forall j, \sum_{s \in \Omega} \mu_j(s) \in]0, N[$$

Les degrés d'appartenance sont compris entre 0 et 1, ils valent 1 pour les pixels du noyau et 0 pour les pixels n'appartenant pas à la région floue. Le second axiome signifie qu'une région floue n'est ni vide, ni complète (égale à Ω). Les régions peuvent se chevaucher.

Cette définition est basée sur la définition de Ruspini d'une partition floue [26], mais sans le troisième axiome qui impose que, pour chaque pixel, la somme des degrés d'appartenance à toutes les régions soit égale à 1. Cet axiome n'est en effet pas intéressant en segmentation, car il peut créer des disparités fortes entre pixels voisins, si l'un appartient à une autre région et pas l'autre et il augmente (jusqu'à la valeur 1) les degrés d'appartenance de pixels loin de tout noyau, s'ils appartiennent à une seule région.

III.3 Méthodes de segmentation floue

III.3.1 L'intégration floue

Kara et Bolon [27] utilisent les résultats de Dubois et les concepts de logique floue pour intégrer des résultats de segmentation issus de méthodes différentes. A partir de n régions R_1, R_2, \dots, R_n obtenues par n méthodes de segmentation et représentant une région R de l'image, une construction d'une région floue est obtenue de la manière suivante. On commence par attribuer un certain degré de confiance à chaque méthode de segmentation. Ce qui revient à donner un poids $m(R_i)$ pour chaque représentation de R_i de façon à avoir $\sum_i m(R_i) = 1$. Dans le cas où on ne dispose pas d'information a priori sur la qualité de chaque segmentation, toutes les régions R_i auront le même poids $m(R_i) = \frac{1}{n}$.

Dès lors, on peut définir une région floue R à l'aide de la fonction d'appartenance μ avec $\forall x \in X, \mu(x) = \sum_{i/x \in R_i} m(R_i)$. X étant l'ensemble des pixels de l'image. La technique proposée dans [27] commence à partir des régions et des coefficients de chaque méthode puis, effectue une mise en correspondance des différentes régions pour déterminer celles qui désignent le même objet de l'image.

III.3.2 Croissance de régions

Dans les méthodes de croissance de régions, le problème est de déterminer les germes des régions, la fonction définissant l'homogénéité des régions et les fonctions d'appartenance. La fonction d'appartenance tient compte de l'homogénéité et de l'éloignement aux germes. Il est proposé dans [28] et [29] une méthode de segmentation floue par croissance de région qui effectue, comme dans la ligne de partage des eaux, une inondation de l'image à partir des points de plus faibles gradients en utilisant une distance topographique. Son principe est le suivant. Les pixels sont d'abord triés par ordre croissant de leur norme du gradient. Les pixels de niveau h sont ajoutés aux bassins calculés jusqu'au niveau $h-1$ ou bien forment un nouveau bassin.

Au niveau h , les supports des régions floues existantes sont étendus, par dilatation conditionnelle des supports des régions au niveau $h-1$, conditionnellement au niveau h . A chaque dilatation de niveau h , chaque pixel ayant au moins un voisin déjà étiqueté est traité. Les étiquettes d'un pixel dépendent des étiquettes de leurs voisins. Si tous les voisins ont la même étiquette, le pixel prendra cette étiquette. S'il y a au moins deux étiquettes différentes, le pixel prendra l'une des étiquettes et les deux régions seront candidates à la fusion. Les dilatations sont répétées jusqu'à ce que tous les pixels qui ont au moins un voisin déjà étiqueté soient étiquetés. Une nouvelle étiquette

de bassin est affectée à chaque ensemble connexe de pixels n'ayant aucun voisin étiqueté. Au moment où deux bassins entrent en contact, l'aire (nombre de pixels) et la profondeur (norme du gradient du cœur) des deux bassins sont examinés : si pour l'un des bassins, l'un ou l'autre de ces attributs est inférieurs à des seuils déterminés, le bassin le plus profond absorbe l'autre. Le degré d'appartenance d'un pixel y à une région R , pris ici dans $[0 ; 255]$ et non pas dans $[0 ; 1]$, est calculé par la relation :

$$\mu(y) = \max_{x \in H(R)} \{0, 255 - dt(x, y)\} \text{ et } \mu(y) = 255 \text{ pour } y \in H(R)$$

Où dt est la distance topographique et $H(R)$ le bassin de la région R [28] et [29].

En cas de fusion, le degré d'appartenance d'un pixel d'une région absorbée est ainsi modifié. $\mu(y) \leftarrow \mu(y) - |f_C - f_A|$. f_C est le niveau du fond du bassin contenant y et f_A est niveau de fond du bassin absorbant.

Notons que la distance topographique est définie comme suit :

Soit f une image définie sur l'ensemble de sites Ω . On note $\mu(x)$ le degré d'appartenance du site x à la région R .

La distance topographique entre deux sites p et q de la région R est définie par cette expression :

$$\pi = \{p = p_1, p_2, \dots, p_{n_\pi} = q\}, p_i \in R$$

$$T(p, q) = \min_{\pi} \sum_{i=2}^{n_\pi} k |f(p_i) - f(p_{i-1})| + dl(p_i, p_{i-1})$$

Où le minimum est pris sur tous les chemins 4-connexe, joignant p et q et inclus dans R .

dl est la distance linéaire et k est une constante positive qui pourra prendre plusieurs valeurs selon la quantification des différents sites et les gradients.

III.3.3 La classification floue

Les méthodes de classification floue des pixels sont très nombreuses et sont toutes basées sur un algorithme de base appelé FCM (Fuzzy C-means).

- **Algorithme FCM**

L'algorithme de classification floue FCM "Fuzzy-C Means" [30] et [31] est très populaire dans le domaine de la classification ou de la segmentation. Il a été aussi utilisé comme modèle dans le seuillage.

Soient $X = \{x_1, x_2, \dots, x_N\}$ 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 μ_{ik} est le degré d'appartenance de l'objet x_i à la classe K , sous la contrainte : $\sum_{k=1}^K \mu_{ik} = 1, \forall i$

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

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

Où τ 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 :

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

Centre de la classe :

$$m_k = \frac{\sum_{i=1}^N \mu_{ik}^\tau x_i}{\sum_{i=1}^N \mu_{ik}^\tau}$$

Avec :

$$1 \leq i \leq N, 1 \leq k \leq K$$

L'algorithme FCM consiste à répéter les opérations de calcul des distances et de mise à jour des degrés d'appartenance et des centres des classes jusqu'à la stabilisation des centres des classes.

III.4 Seuillage flou

Le seuillage flou à pour but de répartir les pixels en deux classes « fond » et « objet » en utilisant les concepts de la logique floue. Plusieurs méthodes de seuillage flou ont été proposées. Nous les avons regroupées en 6 grandes familles :

- Méthode basée sur l'algorithme FCM
- Méthodes basées sur l'indice flou
- Méthode basée sur la mesure d'incertitude
- Méthode basée sur l'entropie floue
- Méthode basée sur la divergence floue
- Méthode basée des mesures de probabilités

III.4.1 Méthode basée sur l'algorithme FCM

L'algorithme FCM a été appliqué par Jawahar et al [32] pour le seuillage d'image

- **Méthode Jawahar et al**

Le seuil optimal s_{opt} est défini comme 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.

$$s_{opt} = arg_{g \text{ equal}}[\mu_f^\tau(g) = \mu_b^\tau(g)]$$

Où $\mu_f^\tau(g)$ et $\mu_b^\tau(g)$ sont respectivement les degrés d'appartenances aux classes « fond » et « objet ». Ils sont définis comme suit :

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

$d(g, m_k)$ 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 τ est l'indice de fuzzification flou.

$$d(g, m_f) = (g - m_k)^2, k = b, f$$

Les centres de ces classes sont calculés comme suit :

$$m_k = \frac{\sum_{g=0}^{N_G-1} g \cdot P(g) \mu_k^\tau(g)}{\sum_{g=0}^{N_G-1} P(g) \mu_k^\tau(g)}; k = f, b$$

L'algorithme de Jawahar et al consiste à choisir initialement un seuil puis répéter les opérations de calcul des centres m_k et les degrés d'appartenances $\mu_k^\tau(g)$.

Le critère d'arrêt est donné par :

$$|m_b^{t+1} - m_b^t| + |m_f^{t+1} - m_f^t| \leq \varepsilon$$

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 :

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

Avec :

$$\beta_k = \frac{\sum_{g=0}^{N_G-1} P(g) \mu_k^\tau(g)}{\sum_{g=0}^{N_G-1} P(g) [\mu_f^\tau(g) + \mu_b^\tau(g)]} \text{ et } \sigma_k^2 = \frac{\sum_{g=0}^{N_G-1} P(g) \mu_k^\tau(g) (g - m_k)^2}{\sum_{g=0}^{N_G-1} P(g) \mu_k^\tau(g)}$$

III.4.2 Méthodes basées sur l'indice flou

III.4.2.1 Indice flou

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

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

Où $d(A, \tilde{A})$ est la distance entre l'ensemble flou A et le sous ensemble ordinaire \tilde{A} le plus proche. \tilde{A} est donné par cette équation :

$$\mu_{\tilde{A}}(x_{mn}) = \begin{cases} 1 & \text{si } \mu_x(x_{mn}) \geq 0.5 \\ 0 & \text{si } \mu_x(x_{mn}) < 0.5 \end{cases}$$

et k est une constante positive de normalisation dont la valeur dépend du type de la distance utilisée. Deux types de distances sont généralement utilisées :

➤ 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 :

$$d_l(A_1, A_2) = \sum_{x \in X} |\mu_{A_1}(x) - \mu_{A_2}(x)|$$

➤ Distance Euclidienne ou quadratique

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

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

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

$$\begin{aligned} \gamma_l(A) &= \frac{2}{n} d_l(A, \tilde{A}) = \frac{2}{n} \sum_{x \in X} |\mu_A(x) - \mu_{\tilde{A}}(x)| = \frac{2}{n} \sum_{x \in X} \mu_{A \cap \tilde{A}}(x) \\ \gamma_q(A) &= \frac{2}{n^{1/2}} d_q(A, \tilde{A}) = \frac{2}{n^{1/2}} \left[\sum_{x \in X} (\mu_A(x) - \mu_{\tilde{A}}(x))^2 \right]^{\frac{1}{2}} \end{aligned}$$

Dans le cas d'une image X de dimension $M \times N$, ces fonctions se traduisent par:[34]

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

Et

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

Si x_{ij} associée à un niveau de gris g ($0 \leq g \leq N_G - 1$), et $h(g)$ correspond au nombre d'occurrence du niveau g , les mesures floues précédentes peuvent alors s'écrire comme suit :

$$\gamma_l(X) = \frac{2}{MN} \sum_{g=0}^{N_G-1} |\mu_X(g) - \mu_{\bar{X}}(g)| \cdot h(g)$$

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

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 associée à une image, cette incertitude peut être déterminée par l'un des indices de flou présentés ci-dessus.

III.4.2.2 Méthode de Chaira et Ray

Les degrés d'appartenance de chaque niveau de gris présent dans une image permettent aux indices de flou γ_l et γ_q donnés respectivement par :

$$\gamma_l(X) = \frac{2}{MN} \sum_{g=0}^{N_G-1} |\mu_X(g) - \mu_{\bar{X}}(g)| \cdot h(g),$$

et

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

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.

Dans [33], les indices de flou γ_l et γ_q prennent les formes suivantes :

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

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

Avec $\mu(g)$ définie par cette équation :

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

m_1 et m_2 correspondent aux centres des classes « fond » et « objet », définies par :

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

c est une constante de normalisation telle que :

$$c = \frac{1}{g_{max} - g_{min}}$$

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

Le seuil optimal est déterminé par la minimisation des indices de flou γ_l ou γ_q .

III.4.3 Méthode basée sur la mesure d'incertitude

III.4.3.1 Mesure d'incertitude

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 :

$$HF(A) = \frac{1}{n \ln 2} \sum_{x \in A} S(\mu_A(x)) = \frac{1}{n \ln 2} \sum_{x \in A} [\mu_A(x) \ln \mu_A(x) + (1 - \mu_A(x)) \ln (1 - \mu_A(x))]$$

Où S est appelée la fonction de Shannon.

Dans le cas d'une image X de dimension $M \times N$, HF se détermine de cette manière: [34]

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

Si x_{ij} associée à un niveau de gris g ($0 \leq g \leq N_G - 1$), et $h(g)$ correspond au nombre d'occurrence du niveau g , les mesures floues précédentes peuvent alors s'écrire comme suit :

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

Avec S la fonction de Shannon telle que :

$$S(\mu_X(g)) = -\mu_X(g) \log(\mu_X(g)) - (1 - \mu_X(g)) \cdot \log(1 - \mu_X(g))$$

Notons qu'en pratique, l'équation de $HF(X)$ est la plus utilisée.

III.4.3.2 Méthode de Huang et Wang

Huang et Wang [35] ont proposé un indice de flou qui mesure la distance entre l'image en niveaux de gris et sa version binaire. L'ensemble de l'image est représentée comme un tableau à deux dimensions :

$$X = \{(i, j), \mu_f[I(i, j)]\}$$

$$\text{Où : } 0 \leq \mu_f[I(i, j)] \leq 1$$

$\mu_f[I(i, j)]$ représente pour chaque pixel de coordonnées (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.

Le seuil optimal est déterminé par la minimisation de l'indice de flou défini 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 donnée par l'équation :

$$\mu_f(g) = \begin{cases} \frac{1}{1 + \frac{|g - m_1(s)|}{D}} & \text{si } g \leq s \\ \frac{1}{1 + \frac{|g - m_2(s)|}{D}} & \text{si } g > s \end{cases}$$

m_1 et m_2 correspondent aux centres des classes « fond » et « objet », définies par :

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

$$D = g_{max} - g_{min}$$

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

Le seuil optimal s_{opt} est celui qui minimise le critère suivant :

$$J(s) = \frac{1}{MN \ln 2} \sum_{g=0}^{N_G-1} h(g) S(\mu_f(g))$$

Avec S la fonction de Shannon telle que :

$$S(\mu_f(g)) = -\mu_f(g)\log(\mu_f(g)) - (1 - \mu_f(g)) \cdot \log(1 - \mu_f(g))$$

Le critère à minimiser prend alors la forme suivante :

$$J(s) = \frac{1}{MN \ln 2} \sum_{g=0}^{N_G-1} \left([\mu_f(g, s) \log(\mu_f(g, s))] + [1 - \mu_f(g, s)] \log[1 - \mu_f(g, s)] \right) h(g)$$

III.4.4 Méthode basée sur l'entropie floue

III.4.4.1 Entropie floue

Selon la théorie de l'information, l'entropie est une mesure de quantité d'information d'un système. Soit un ensemble fini $S = \{s_1, s_2, \dots, s_k\}$ d'événements indépendants, et p_i la probabilité d'occurrence de chaque élément s_i , l'entropie est définie par :

$$H(S) = - \sum_{i=1}^k p_i \log p_i$$

Plus l'entropie est grande, plus on a des informations. Plusieurs méthodes de segmentation d'images l'ont utilisé dans le but de maximiser la qualité de l'information obtenue du résultat final. [36].

Si l'ensemble S est considéré comme un ensemble flou avec le degré d'appartenance correspondant à chaque élément dans S $\mu_S(S_i)$, $i=\overline{1, k}$, est la fonction d'appartenance, alors l'entropie floue de l'ensemble S est définie par :

$$H_{floue}(S) = \sum_{i=1}^k \mu_S(S_i) * p_i * \log p_i$$

$$\text{Où } 0 \leq \mu_S(S_i) \leq 1$$

Le principe des méthodes de seuillage flou est de chercher une partition de l'image dont l'entropie est la plus grande. De nombreuses méthodes sont proposées en se basant sur des variations de l'entropie d'une partition. On va voir ci-dessous trois exemples dans le cas de seuillage.

III.4.4.2 Méthode Chang et al

Dans cette méthode, les degrés $\mu_b(g)$ et $\mu_f(g)$ d'appartenance d'un niveau de gris aux classes fond et objet sont définis par les équations : (Fig.III.1)

$$\mu_b(g) = \begin{cases} 0 & \text{si } g \leq a \\ \frac{g-a}{c-a} & \text{si } a < g < c \\ 1 & \text{si } c \leq g \end{cases}; \quad \mu_f(g) = \begin{cases} 1 & \text{si } g \leq a \\ \frac{g-c}{a-c} & \text{si } a < g < c \\ 0 & \text{si } c \leq g \end{cases}$$

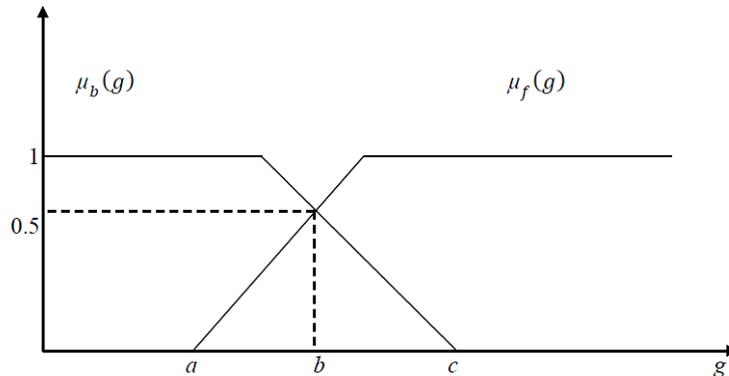


Fig.III.1- Courbe des degrés d'appartenance.

Le seuil s est généralement compris entre a et c et correspond à la valeur de g qui vérifie $\mu_b(g) = \mu_f(g) = 0.5$. Il correspond aussi au point de croisement b . La valeur du seuil est alors :

$$s = \frac{a + c}{2}$$

Les valeurs des paramètres a et c sont déterminés en maximalisant l'entropie suivante :

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

avec
$$P_b = \sum_{g=0}^{N_G-1} \frac{h(g)}{N} \mu_b(g) \quad \text{et} \quad P_f = \sum_{g=0}^{N_G-1} \frac{h(g)}{N} \mu_f(g)$$

Les valeurs optimales de a_{op} et c_{op} sont alors utilisées pour le calcul du seuil

$s = (a_{op} + c_{op})/2$. Le calcul de a_{op} et c_{op} peut se faire d'une manière exhaustive ou par l'intermédiaire de l'algorithme du recuit simulé. [37].

III.4.4.3 Méthode de Tao et al

Tao et al [38] définissent les degrés d'appartenance $\mu_b(g)$ et $\mu_f(g)$ d'un niveau de gris g aux classes « fond » et « objet » de la manière suivante :

$$\mu_b(g) = \begin{cases} 1 & \text{si } g \leq a \\ 1 - \frac{(g-a)^2}{(c-a)(b-a)} & \text{si } a < g \leq b \\ \frac{(g-a)^2}{(c-a)(c-b)} & \text{si } b < g \leq c \\ 0 & \text{si } g > c \end{cases}$$

$$\mu_f(g) = \begin{cases} 0 & \text{si } g \leq a \\ \frac{(g-a)^2}{(c-a)(b-a)} & \text{si } a < g \leq b \\ 1 - \frac{(g-c)^2}{(c-a)(c-b)} & \text{si } b < g \leq c \\ 0 & \text{si } g > c \end{cases}$$

avec bien sur : $\mu_b(g) + \mu_f(g) = 1$

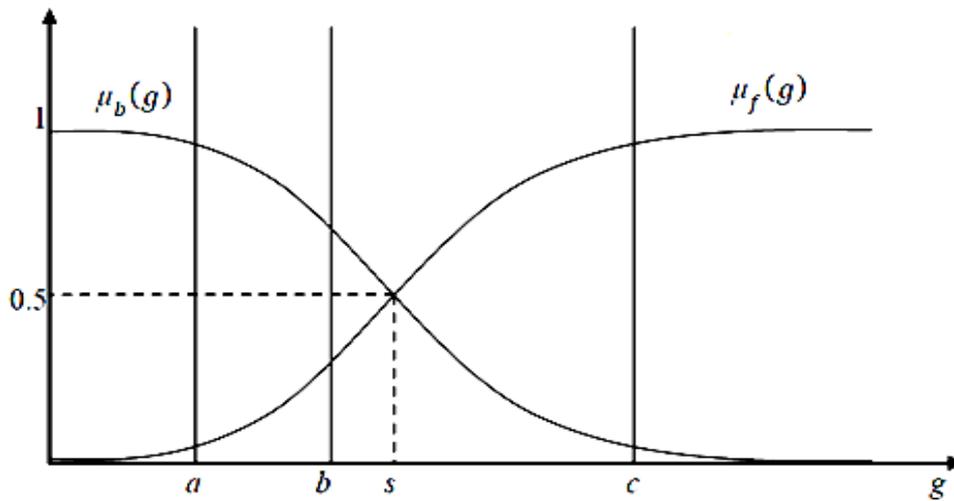


Fig.III.2- Courbe des degrés d'appartenance.

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

Pour déterminer la valeur du seuil, Tao et al proposent de calculer les paramètres a , b et c qui maximisent l'entropie suivante :

$$H(a, b, c) = H_b(a, b, c) + H_f(a, b, c)$$

Où
$$H_b(a, b, c) = - \sum_{g=0}^{N_G-1} \frac{h(g)\mu_b(g)}{NP_b} \log \left(\frac{h(g)\mu_b(g)}{NP_b} \right)$$

$$H_f(a, b, c) = - \sum_{g=0}^{N_G-1} \frac{h(g)\mu_f(g)}{NP_f} \log \left(\frac{h(g)\mu_f(g)}{NP_f} \right)$$

Avec
$$P_b = \sum_{g=0}^{N_G-1} \frac{h(g)}{N} \mu_b(g) \quad \text{et} \quad P_f = \sum_{g=0}^{N_G-1} \frac{h(g)}{N} \mu_f(g)$$

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 [39] ou les colonies de fourmis[38].

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

$$s_{op} = \begin{cases} a_{op} + \sqrt{\frac{(c_{op} - a_{op})(b_{op} - a_{op})}{2}} & \text{si } \frac{a_{op} + c_{op}}{2} \leq b_{op} \leq c_{op} \\ c_{op} - \sqrt{\frac{(c_{op} - a_{op})(c_{op} - b_{op})}{2}} & \text{si } a_{op} \leq b_{op} \leq \frac{a_{op} + c_{op}}{2} \end{cases}$$

III.4.4.4 Méthode de Liu et al

Liu et al proposent de déterminer la valeur du seuil en maximisant l'entropie floue suivante : [40]

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

Avec $P_b = \sum_{g=0}^{N_G-1} \frac{h(g)}{\mu_b(g)}$ et $P_f = \sum_{g=0}^{N_G-1} \frac{h(g)}{\mu_f(g)}$

Les degrés d'appartenance $\mu_f(g)$ et $\mu_b(g)$ sont calculés de la même manière que dans la méthode de Huang et Wang :

$$\begin{cases} \mu_f(g) = \frac{1}{1 + \frac{|g - m_1(s)|}{D}} & \text{si } g \leq s \\ \mu_b(g) = \frac{1}{1 + \frac{|g - m_2(s)|}{D}} & \text{si } g > s \end{cases}$$

Avec $m_1(s) = \frac{\sum_{g=0}^s gh(g)}{\sum_{g=0}^s h(g)}$ et $m_2(s) = \frac{\sum_{g=s+1}^{N_G-1} gh(g)}{\sum_{g=s+1}^{N_G-1} h(g)}$

$$D = g_{max} - g_{min}$$

III.4.4.5 Méthodes de Braviano

Braviano propose deux variantes de seuillage basées sur l'entropie floue mais en considérant la totalité de la dynamique, même en dehors de l'intervalle d'incertitude [41]

- **Variante 1**

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

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

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

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

La valeur de seuil s peut être déterminée en minimisant l'incertitude :

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

Sachant que :

$$S(\mu_X(g)) = -\mu_X(g) \log(\mu_X(g)) - (1 - \mu_X(g)) \cdot \log(1 - \mu_X(g))$$

En négligeant le terme $\ln 2$ et sachant que le seuil est dans l'intervalle $[s - k, s + k]$, ou k est un paramètre fixé au préalable, $HF(X)$ devient :

$$\begin{aligned} HF(X) &= HF(b) + HF(f) \\ HF(X) &= - \sum_{g=0}^{s+k} p_g \left[\frac{\mu_f(g)}{P_f} \ln \left(\frac{\mu_f(g)}{P_f} \right) + \left(1 - \frac{\mu_f(g)}{P_f} \right) \ln \left(1 - \frac{\mu_f(g)}{P_f} \right) \right] \\ &\quad - \sum_{g=s-k}^{N_G-1} p_g \left[\frac{\mu_b(g)}{P_b} \ln \left(\frac{\mu_b(g)}{P_b} \right) + \left(1 - \frac{\mu_b(g)}{P_b} \right) \ln \left(1 - \frac{\mu_b(g)}{P_b} \right) \right] \\ HF(X) &= - \left[\frac{1}{P_f} \ln \left(\frac{1}{P_f} \right) + \left(1 - \frac{1}{P_f} \right) \ln \left(1 - \frac{1}{P_f} \right) \right] \sum_{g=0}^{s+k} p_g \\ &\quad - \sum_{g=s-k}^{s+k} p_g \left[\frac{\mu_f(g)}{P_f} \ln \left(\frac{\mu_f(g)}{P_f} \right) + \left(1 - \frac{\mu_f(g)}{P_f} \right) \ln \left(1 - \frac{\mu_f(g)}{P_f} \right) \right] \\ &\quad - \sum_{g=s-k}^{s+k} p_g \left[\frac{\mu_b(g)}{P_b} \ln \left(\frac{\mu_b(g)}{P_b} \right) + \left(1 - \frac{\mu_b(g)}{P_b} \right) \ln \left(1 - \frac{\mu_b(g)}{P_b} \right) \right] \\ &\quad - \left[\frac{1}{P_b} \ln \left(\frac{1}{P_b} \right) + \left(1 - \frac{1}{P_b} \right) \ln \left(1 - \frac{1}{P_b} \right) \right] \sum_{g=s-k}^{N_G-1} p_g \end{aligned}$$

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.

- **Variante 2**

Les deux distributions précédentes sont légèrement modifiées :

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

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

où
$$P_f = \sum_{g=0}^{s+k} \mu_f(g) \cdot p_g \text{ et } P_b = \sum_{g=s-k}^{N_G-1} \mu_b(g) \cdot p_g$$

Dans ce cas, les distributions associent la fréquence et le degré d'appartenance de chaque niveau de gris. 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 :

$$\begin{aligned} HF(X) &= HF(b) + HF(f) \\ HF(X) &= - \sum_{g=0}^{s-k-1} \left[\frac{p_g}{P_f} \ln \left(\frac{p_g}{P_f} \right) + \left(1 - \frac{p_g}{P_f} \right) \ln \left(1 - \frac{p_g}{P_f} \right) \right] \\ &\quad - \sum_{g=s-k}^{s+k} \left[\frac{\mu_f(g) p_g}{P_f} \ln \left(\frac{\mu_f(g) p_g}{P_f} \right) + \left(1 - \frac{\mu_f(g) p_g}{P_f} \right) \ln \left(1 - \frac{\mu_f(g) p_g}{P_f} \right) \right] \\ &\quad - \sum_{g=s-k}^{s+k} \left[\frac{\mu_b(g) p_g}{P_b} \ln \left(\frac{\mu_b(g) p_g}{P_b} \right) + \left(1 - \frac{\mu_b(g) p_g}{P_b} \right) \ln \left(1 - \frac{\mu_b(g) p_g}{P_b} \right) \right] \\ &\quad - \sum_{g=s+k+1}^{N_G-1} \left[\frac{p_g}{P_b} \ln \left(\frac{p_g}{P_b} \right) + \left(1 - \frac{p_g}{P_b} \right) \ln \left(1 - \frac{p_g}{P_b} \right) \right] \end{aligned}$$

Le seuil optimal est celui qui minimise $HF(X)$.

III.4.4.6 Méthode de Shanbag

Shanbag [42] considère les degrés d'appartenance d'un niveau de gris au fond ou à 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 à g niveaux de gris au dessus ou au dessous d'un seuil s donné, on a les degrés d'appartenance suivants :

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

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

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

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

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

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

$$s_{opt} = \operatorname{argmin} \{ | H_f(s) - H_b(s) | \}$$

$$\text{où } H_f(s) = - \sum_{g=0}^s \frac{p(s)}{P(s)} \log[\mu_f(g)] \text{ et } H_b(s) = - \sum_{g=s+1}^{N_G-1} \frac{p(s)}{1 - P(s)} [\mu_b(g)]$$

$$\text{avec } P(s) = \sum_{g=0}^s \frac{gh(g)}{N}$$

III.4.5 Méthode basée sur la divergence floue

III.4.5.1 Divergence floue

Soit A et B deux ensembles flous définis dans $X = \{x_0, x_1, \dots, x_{N-1}\}$ 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 :

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

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

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

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

$$D_i(B, A) = -\mu_A(x_i) \ln \frac{\mu_A(x_i)}{\mu_B(x_i)} - [1 - \mu_B(x_i)] \ln \frac{1 - \mu_A(x_i)}{1 - \mu_B(x_i)}$$

La seconde partie de ces deux dernières formes de $D_i(A, B)$ 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 équations précédentes seront remplacées par :

$$\begin{aligned} D_i(A, B) &= \mu_A(x_i) \ln \frac{1 + \mu_A(x_i)}{1 + \mu_B(x_i)} + [1 - \mu_A(x_i)] \ln \frac{2 - \mu_A(x_i)}{2 - \mu_B(x_i)} \\ D_i(B, A) &= \mu_B(x_i) \ln \frac{1 + \mu_B(x_i)}{1 + \mu_A(x_i)} + [1 - \mu_B(x_i)] \ln \frac{2 - \mu_B(x_i)}{2 - \mu_A(x_i)} \\ D_i(B, A) &= -\mu_A(x_i) \ln \frac{1 + \mu_A(x_i)}{1 + \mu_B(x_i)} - [1 - \mu_B(x_i)] \ln \frac{2 - \mu_A(x_i)}{2 - \mu_B(x_i)} \end{aligned}$$

La forme finale de $D(A, B)$ est donnée comme suit :

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

III.4.5.2 Méthode de Bandari et al [47]

La maximisation de la divergence floue peut être utilisée pour trouver le niveau de gris le plus ambigu dans l'histogramme [43], en choisissant les degrés d'appartenances $\mu_b(g)$ et $\mu_f(g)$, en choisissant aussi l'intervalle d'incertitude $[s - k, s + k]$ et poser $\mu_b(s) = \mu_f(s) = 0.5$. Comme $\mu_b(s) + \mu_f(s) = 1 \forall x_i \in X$, $D_i(b, f) = D_i(f, b)$. Le seuil est obtenu en maximisant la divergence entre l'objet et le fond, définie comme suit :

$$\left\{ \frac{2}{N} \sum_{g=0}^{N_G-1} D_i(b, f) h(g) \right\}$$

Où $D_i(b, f)$ est donnée par cette équation :

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

Avec $D_i(A, B) = D_i(b, f)$.

Par conséquent le seuil optimal s est:

$$s_{opt} = \operatorname{argmax} \left\{ \frac{2}{N_G - 1} \sum_{g=0}^{N_G-1} [2\mu_b(g) - 1] \ln \frac{1 + \mu_b(g)}{1 - \mu_b(g)} h(g) \right\}$$

III.4.5.3 Méthodes de Chaira et Ray

Une autre méthode de seuillage basée sur la divergence floue à été proposée par *Chaira et Ray* [44]. La divergence floue d'une image X est déterminée à partir de l'entropie exponentielle définie comme suit :

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

Où $\mu(x_{ij})$ est le degré d'appartenance du pixel de coordonnées (i, j) , ayant le niveau de gris $x_{ij} = g$.

Il est défini par :

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

m_1 et m_2 correspondent aux centres des classes « fond » et « objet », sont définies par :

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

c est une constante de normalisation telle que :

$$c = \frac{1}{g_{max} - g_{min}}$$

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

La divergence entre deux images X et Y est définie par Chaira et Ray par:

$$D_i(X, Y) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [1 - (1 - \mu(x_{ij}))e^{\mu_X(x_{ij}) - \mu_Y(x_{ij})} - \mu_X(x_{ij})e^{\mu_Y(x_{ij}) - \mu_X(x_{ij})}]$$

Ainsi la divergence totale est :

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

$$D_i(X, Y) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [2 - (1 - \mu_X(x_{ij}) + \mu_Y(x_{ij}))e^{\mu_X(x_{ij}) - \mu_Y(x_{ij})} - (1 - \mu_Y(x_{ij}) + \mu_X(x_{ij}))e^{\mu_Y(x_{ij}) - \mu_X(x_{ij})}]$$

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 :

$$D_i(X, Y) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [2 - (2 - \mu_X(x_{ij}))e^{\mu_X(x_{ij})-1} - \mu_X(x_{ij})e^{1-\mu_X(x_{ij})}]$$

Qu'on peut mettre sous la forme :

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

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

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

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

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

III.4.6 Méthode basée des mesures de probabilités

III.4.6.1 Principe

Soit deux ensembles disjoints $X_1 = \{0, 1, \dots, k_1\}$ et $X_2 = \{k_1+1, k_1+2, \dots, k_2\}$. 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 [43]

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

où
$$P = \sum_{k_1=0}^{k_1} \sum_{j=k_1+1}^{k_2} \mu_D(x_i, x_j) P(x_i, X_1) P(x_j, X_2)$$

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

Pour appliquer cette mesure de dissimilarité au seuillage, on considère pour chaque seuil s possible, les paramètres k_1 et k_2 comme étant s et $N_G - 1$ respectivement. La fonction μ_D entre 2 niveaux de gris g et \bar{g} peut être définie de plusieurs manières :

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

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

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

$$P = \sum_{g=0}^{k_1} \sum_{\bar{g}=k_1+1}^{k_2} \mu_D(g, \bar{g}) P(g, b) P(\bar{g}, f)$$

III.4.6.2 Méthode paramétrique

Les deux distributions de probabilité, celle de fond $P(g, b)$ et celle de l'objet $P(g, f)$, peuvent être approchées par deux lois normales ou deux distributions de poisson. Dans le premier cas, la probabilité P prend la forme suivante :

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

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

$$\sigma_1(s) = \frac{\sum_{g=0}^s [1-m_1(s)]^2 h(g)}{\sum_{g=0}^s h(g)} \quad \text{et} \quad \sigma_2(s) = \frac{\sum_{g=s+1}^{N_G-1} [1-m_2(s)]^2 h(g)}{\sum_{g=s+1}^{N_G-1} h(g)}$$

Dans le deuxième cas, la probabilité P devient :

$$P(s) = \left\{ \sum_{g=0}^s \sum_{\bar{g}=s+1}^{N_G-1} \mu_D(g, \bar{g}) \frac{(m_1(s))^g}{g!} e^{-m_1(s)} \frac{(m_1(s))^{\bar{g}}}{\bar{g}!} e^{-m_2(s)} \right\}$$

Le seuil optimal est obtenu en maximisant l'une des probabilités $P(s)$.

III.4.6.3 Méthode non paramétrique

Dans ce cas, les fonctions de probabilités $P(g, b)$ et $P(g, f)$ sont inconnues, mais qui peuvent être estimées à partir de l'histogramme de l'image. On considère l'histogramme comme représentant de deux distributions de probabilité. Le seuil optimal est :

$$s = \operatorname{argmax}_{s=0 \dots N_G-1} \left\{ \sum_{g=0}^s \sum_{\bar{g}=s+1}^{N_G-1} \mu_D(g, \bar{g}) \frac{h(g)}{\sum_{k=0}^s h(k)} \frac{h(\bar{g})}{\sum_{k=s+1}^{N_G-1} h(k)} \right\}$$

III.4.7 Méthode basée sur la géométrie floue

III.4.7.1 Méthode de Pal

Pal et *Rosenfeld* [45] ont utilisé le concept de la géométrie floue pour déterminer le seuil optimal en maximisant la compacité floue définie comme suit :

$$s_{opt} = \operatorname{argmax} \left\{ \operatorname{compacité}[\mu(s)] = \frac{\operatorname{surf}[\mu(s)]}{[\operatorname{perim}[\mu(s)]]^2} \right\}$$

Où *Surf* représente la Surface, telle que :

$$\operatorname{surf}(\mu(s)) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \mu[I(i,j)]$$

Perim est le Périmètre, qui est défini par :

$$\begin{aligned} \operatorname{perim}(\mu(s)) &= \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} |\mu[I(i,j)] - \mu[I(i,j+1)]| \\ &+ \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} |\mu[I(i,j)] - \mu[I(i+1,j)]| \end{aligned}$$

En pratique, pour assigner la fonction d'appartenance au pixel de coordonnées $(i,j) : \mu(i,j) = S[I(i,j); a, b, c]$, on peut utiliser la fonction standard S_z définie de cette manière :

$$S_z(g) = \begin{cases} 0 & \text{si } g \leq s - k \\ 2 \left[\frac{g - (s - k)}{2k} \right]^2 & \text{si } s - k < g \leq s \\ 1 - \left[\frac{g - (s + k)}{2k} \right]^2 & \text{si } s < g \leq s + k \\ 1 & \text{si } g > s + k \end{cases}$$

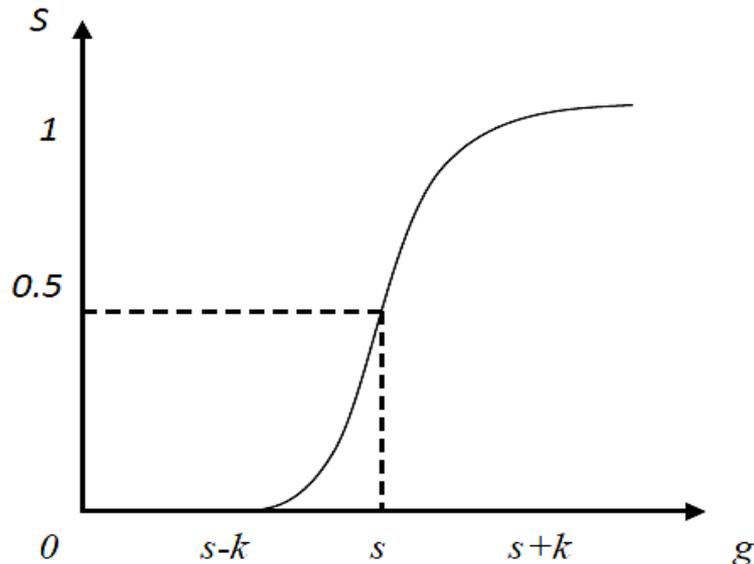


Fig.III.3- Fonction S_z de Zadeh

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 Δb , on peut déterminer pour chaque pixel $\mu(I(i, j))$, b et Δb sont connus à priori.

On retrouve la même méthode dans [33] où $\mu(I(i, j))$ est déterminé par :

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

m_1 et m_2 correspondent aux centres des classes « fond » et « objet », sont définies par :

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

c est une constante de normalisation telle que :

$$c = \frac{1}{g_{max} - g_{min}}$$

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

III.5. Conclusion

Dans ce chapitre, nous avons présenté une panoplie de méthodes de seuillage flou. Chaque méthode est caractérisée par la manière de calculer le degré d'appartenance d'un pixel à une classe, et par un critère d'optimisation pour calculer le seuil optimal.

La majorité de ces méthodes sont basées sur des notions de probabilité, d'entropie, de la divergence floue, d'indice flou, d'incertitude floue et de géométrie floue. Elles appartiennent à la catégorie de la logique de type 1.

Notons que quelques méthodes de seuillage flou utilisant des notions de logique floue de type 2 ont été récemment proposées dans la littérature.

Parmi toutes les méthodes de seuillage flou présentées dans ce chapitre, nous nous sommes intéressé particulièrement à celles de Chaira et Ray, Huang et Wang, Chang et al, Tao et al, Liu et al, les méthodes qui sont basées sur la divergence floue et la méthode qui est basée sur des mesures de probabilités (non paramétrique) .

CHAPITRE IV

Tests et Interprétation

Des résultats

IV.1 Introduction

Dans ce chapitre, on se propose de tester, d'interpréter et de comparer quelques méthodes de seuillage flou qui sont présentées dans le chapitre précédent à savoir la méthode de Chaira et Ray, de Huang et Wang, de Chang et al, de Tao et al, de Liu et al, de Bhandari et al, de divergence flou proposée par Chaira et de probabilité non paramétrique, ainsi que la méthode de seuillage hard qu'est la méthode d'Otsu.

L'ensemble des méthodes ont été implémentées sous MATLAB 7.10 sur un ordinateur PC doté d'un microprocesseur de type Intel(R) à 1.86 Ghz/s et de 2Gbits de mémoire vive.

L'évaluation des résultats sera effectuée sur des images réelles appartenant à des domaines différents, médical, document historique, apiculture.

Deux critères de comparaison en plus du temps de calcul, nous permettent d'évaluer la qualité des résultats de seuillage.

IV.2 Critères de comparaison des résultats [46]

IV.2.1 L'Uniformité

Livin et Nazif ont proposés cet algorithme ci-dessous pour calculer le premier critère de comparaison :

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

Avec :

g_i : est le niveau de gris de $i^{\text{ème}}$ pixel.

R_j : représente la $j^{\text{ème}}$ région segmentée avec $j = 1, 2, \dots, K$.

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 région R_i .

Dans le cas de binarisation, on aura :

g_i : est le $i^{\text{ème}}$ niveau de gris de pixel.

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

$K = 2$, représente le nombre de classes

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

m_i : 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.

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

IV.2.2 La Divergence entre l'image aux niveaux de gris et l'image 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 $i^{\text{ème}}$ pixel.

$thresh_i(k)$: est le niveau de gris de $i^{\text{ème}}$ 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 :

$$thresh_i(k) = \begin{cases} m_k & \text{si } i \in C_k \\ 0 & \text{ailleurs} \end{cases}$$

Dans le cas de binarisation, on aura :

$K = 2$ représente le nombre de classes (fond et objet)

g_i : est le i ème niveau de gris.

$thresh_i(k) = s$: est le seuil de binarisation.

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

IV.3 Résultats et comparaison

Dans cette partie, nous allons présenter les résultats obtenus par les différentes méthodes de seuillage flou, sur des images réelles appartenant à des domaines différents.

IV.3.1 Médical

L'IRM ou imagerie par résonance magnétique, fait partir des examens complémentaires d'imagerie médicale tout comme la radiographie, l'échographie ou le scanner.

a)- Définition de l'IRM

L'IRM est une technique de diagnostic médical puissante qui fournit des images tridimensionnelles et en coupe de grande précision anatomique. L'IRM est une technique radiologique récente, non invasive et sans effets secondaires connus, basée sur le phénomène physique de résonance magnétique nucléaire. Il s'agit simplement d'observer la résonance magnétique nucléaire (RMN) des protons de l'eau contenus dans l'organisme, c'est à dire la réponse des noyaux soumis à un champ magnétique extérieur et à une excitation électromagnétique.

L'intensité recueillie pour un élément de volume (voxel) dépend de la concentration de l'eau à l'endroit considéré et on obtient ainsi une image tridimensionnelle de la répartition de l'eau dans le corps d'un patient. Selon la méthode utilisée, le contraste entre deux voxels peut être augmenté si les temps de relaxation des spins nucléaires (décrivant le retour à l'équilibre des noyaux après l'excitation) est différent dans les deux zones. Il est donc possible d'observer des altérations des tissus (telles que des tumeurs) grâce aux différences de densité et de relaxation de l'eau.

b)- Image d'IRM

Dans cet exemple, on va utiliser le seuillage flou pour détecter une tumeur au niveau des poumons d'une personne. L'image ainsi que son histogramme sont présentés sur la figure (Fig.IV-1).

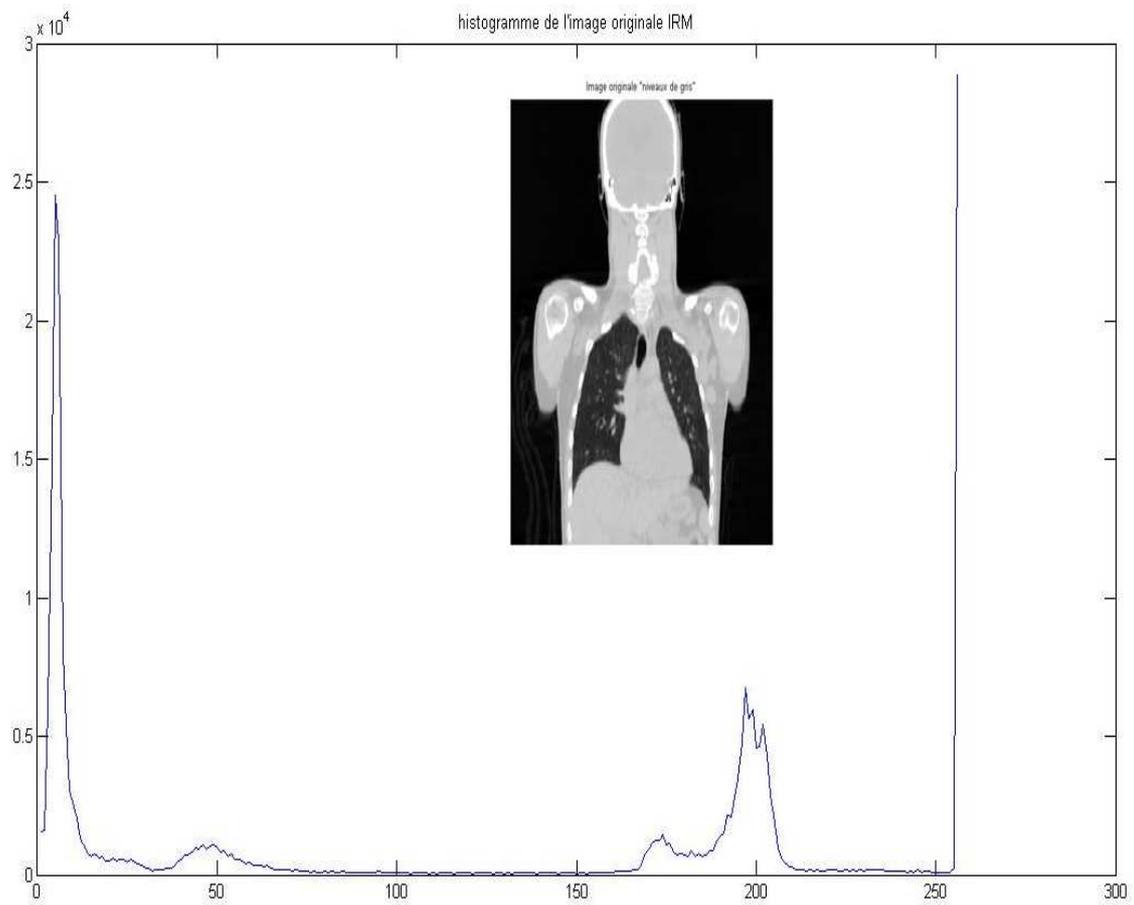


Fig.IV-1- : Image IRM originale et son histogramme.

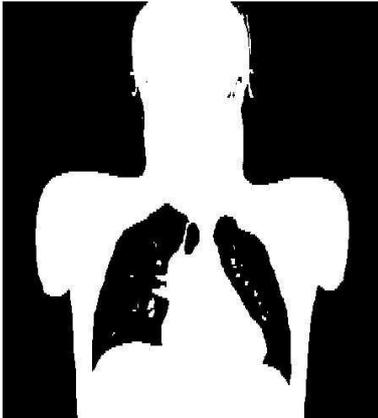
Les résultats des tests sont donnés dans ce tableau suivant :

Critères de comparaison Algorithmes		Seuil optimal	Critère d'Uniformité	Critère de Divergence	Temps de calcul (s)
Otsu		111	0.97933	0.0519	0.1124
Huang et Wang		51	0.9586	0.073375	0.50649
Chaira et Ray		113	0.97933	0.051853	0.14001
Chang et al		5	0.77771	0.17003	1.0856
Tao et al		171	0.96567	0.066814	294.9668
Liu et al		167	0.97347	0.058737	0.023795
Probabilité non paramétrique		114	0.97932	0.051858	70.6559
La divergence floue	Bhandari et al	124	0.9791	0.052137	0.0082119
	D-F-Chaira 1	112	0.97933	0.05185	0.094158
	D-F-Chaira 2	113	0.97933	0.051853	0.076232

Tableau.VI-1- Résultats des seuillages de l'image IRM.

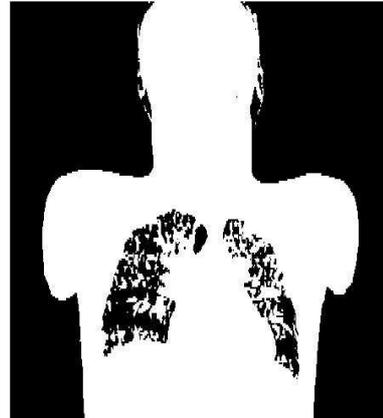
Les images seuillées sont données comme suit :

Image divergence par Chaira-cas1-



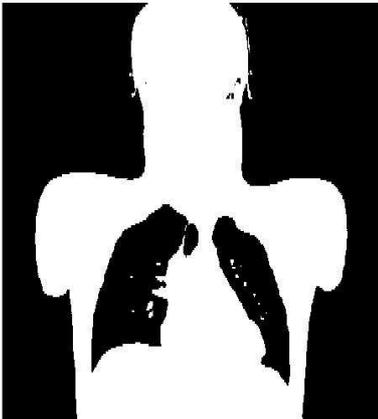
Seuil de diver- floue de Chaira, cas 1

Image Huang



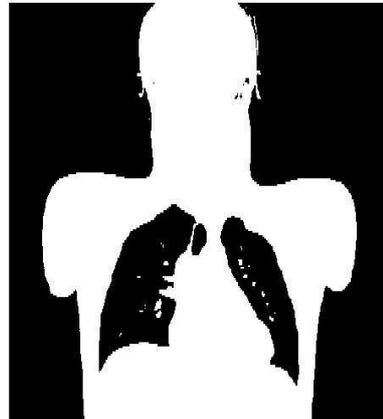
Seuil de Huang

Image divergence floue



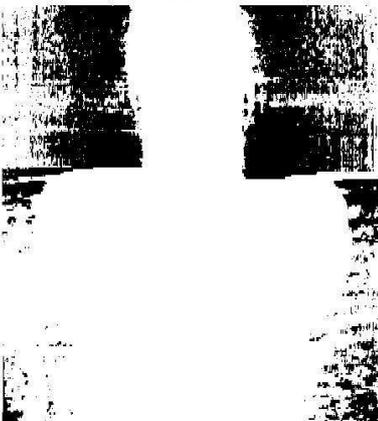
Seuil de Bhandari et al

Image divergence par Chaira-cas2-



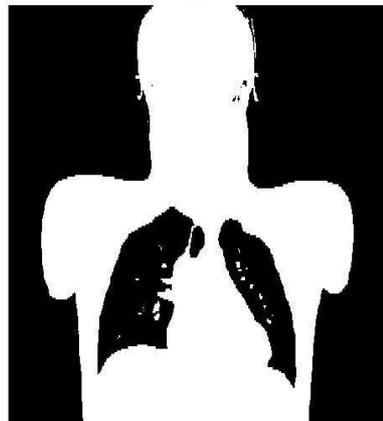
Seuil de diver- floue de Chaira, cas 2

Image Chang



Seuil de Chang

Image chaira



Seuil de Chaira

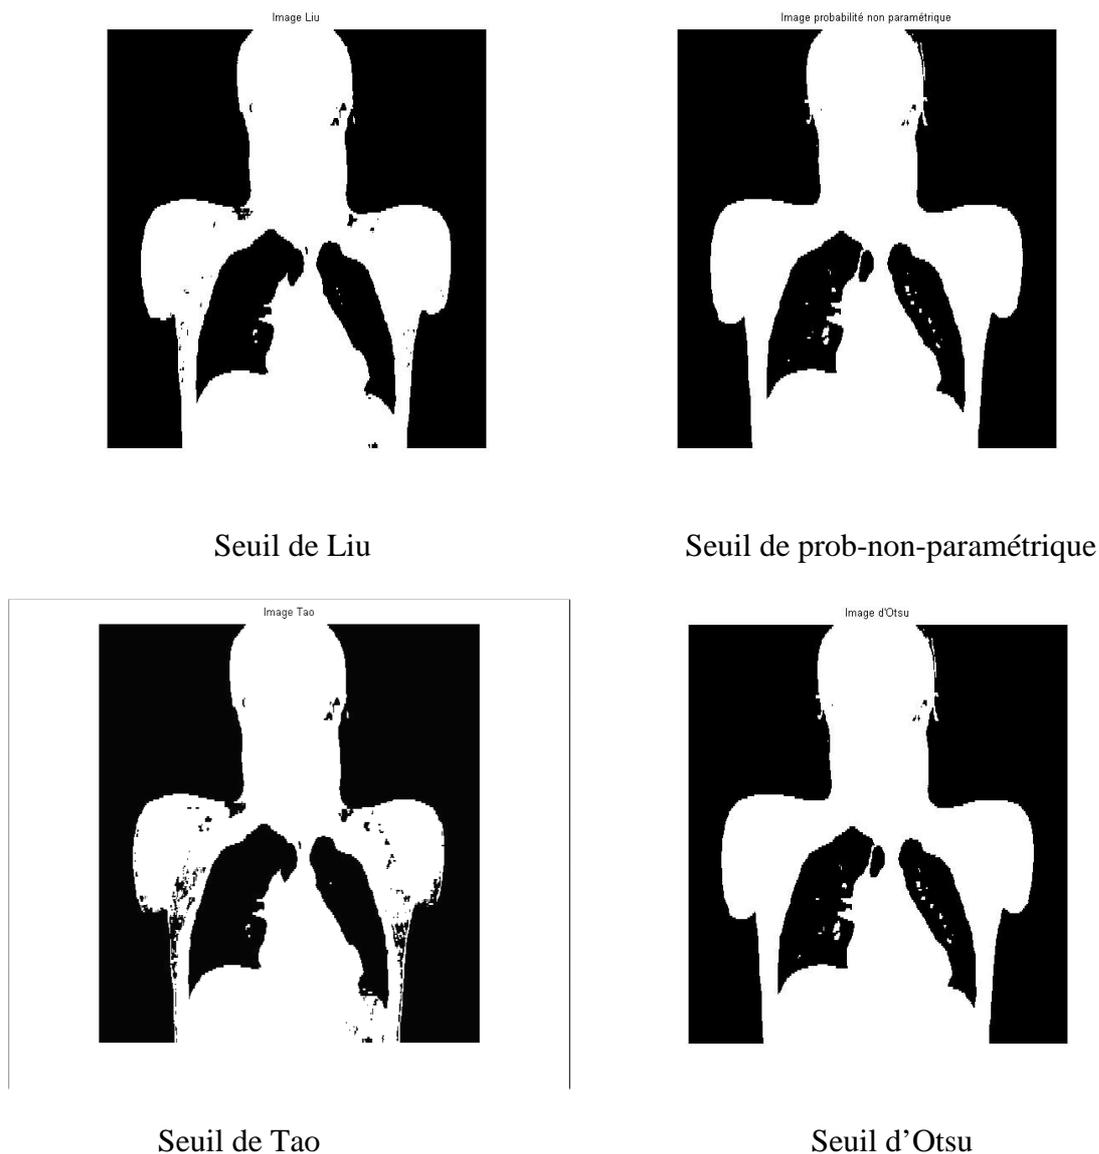


Fig.IV-2- : Image IRM binarisée par différent seuils.

En se basant sur le principe des deux critères de comparaison (l'uniformité et la divergence), les méthodes de probabilité non paramétrique, de Chaira et celles de divergence floue proposées par Chaira sont les plus performantes. On remarque que les seuils fournis par ces méthodes sont plus proches à celui d'*Otsu*. Par contre la méthode de Bhandari et al est la meilleure selon le temps de calcul. Les méthodes citées précédemment et celle d'*Otsu* séparent bien les pixels des tâches blanches dans les poumons des autres pixels. Ce qui nous permet d'identifier la tumeur au niveau des poumons.

IV.3.2 L'Apiculture

L'apiculture est le domaine qui étudie le monde des abeilles. Dans cette partie, on se base sur les petites espèces qui attaquent les abeilles, appelés : les varroas.

a)- Définition de varroas

Les varroas sont des petites espèces qui attaquent les abeilles, ainsi que leurs œufs. Les varroas sont des arachnides ou plus précisément des acariens voraces. La femelle du varroa est plus grosse.

b)- Exemple

Dans cet exemple, les méthodes de seuillage flou sont utilisées pour détecter la présence du varroa. (Fig.IV-3)

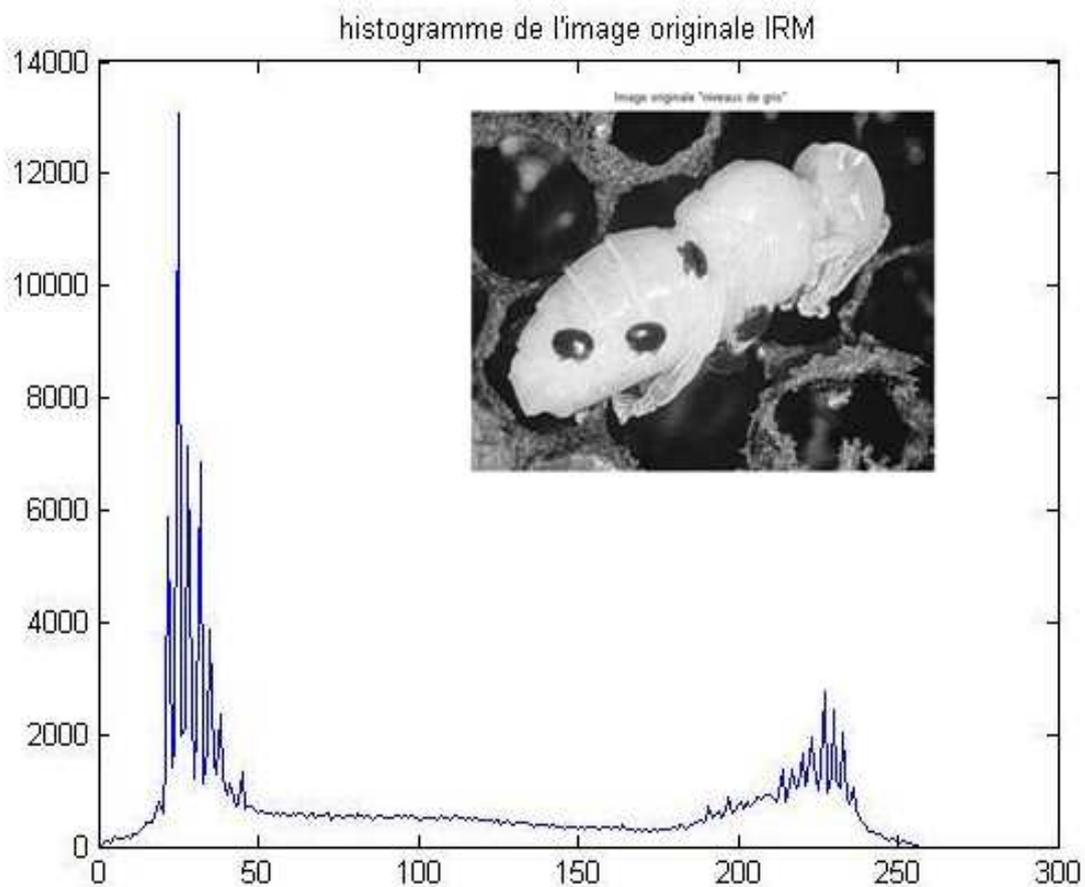


Fig.IV-3- : Image d'une abeille de 12 jours originale et son histogramme.

Les résultats des tests sont donnés dans ce tableau suivant :

Algorithmes	Critères de comparaison	Seuil optimal	Critère d'Uniformité	Critère de Divergence	Temps de calcul (s)
Otsu		123	0.9696	0.0720	0.0842
Huang et Wang		108	0.96781	0.074122	0.3655
Chaira et Ray		124	0.96962	0.072004	0.1138
Chang et al		27	0.85055	0.1597	1.2437
Tao et al		181	0.95146	0.091013	242.1783
Liu et al		128	0.9695	0.07215	0.02141
Probabilité non paramétrique		163	0.96072	0.081871	73.1205
La divergence floue	Bhandari et al	1	0.8018	0.18391	0.0083206
	D-F-Chaira 1	123	0.96962	0.072008	0.0207
	D-F-Chaira 2	124	0.96962	0.072004	0.1007

Tableau.IV-2- Résultats des seuillages de l'image d'abeille de 12 jours.

Les images seuillées sont données comme suit :



Seuil de Liu



Seuil de diver-floue de Chaira, cas 1



Seuil de Huang

Bhandari et al



Seuil de diver-floue de Chaira, cas 2



Seuil de proba-non-paramétrique

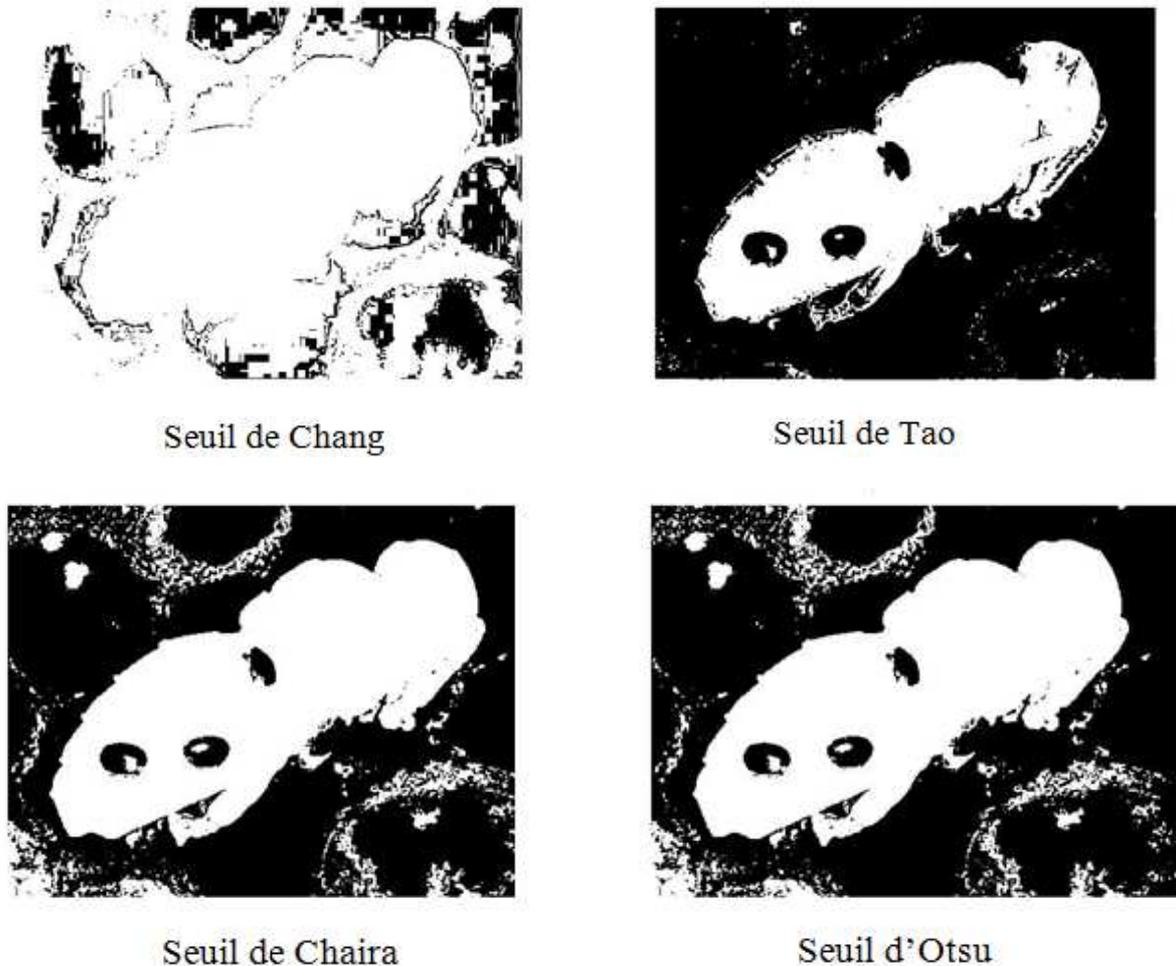


Fig.IV-4- : Image d'abeille de 12 jours binarisée par différents seuils.

En se basant sur le principe des deux critères de comparaison, les méthodes de Liu et al, de Chaira et celles de divergence floue (Chaira), sont les plus performantes. Leurs valeurs des seuils sont plus proches à celle d'*Otsu*. Par contre la méthode de Bhandari et al est la meilleure selon le temps de calcul, mais le problème, elle ne nous donne pas un très bon seuil. Les méthodes citées précédemment ainsi que celle d'*Otsu* permettent d'identifier les 3 varroas sur le dos et un varroa collé sur le côté droit de l'abeille.

VI.3.3 Document historique

Nous intéressons dans cette partie à l'utilisation du seuillage flou pour décoder ce qui est écrit sur l'image d'un ancien article (Fig.IV-5).

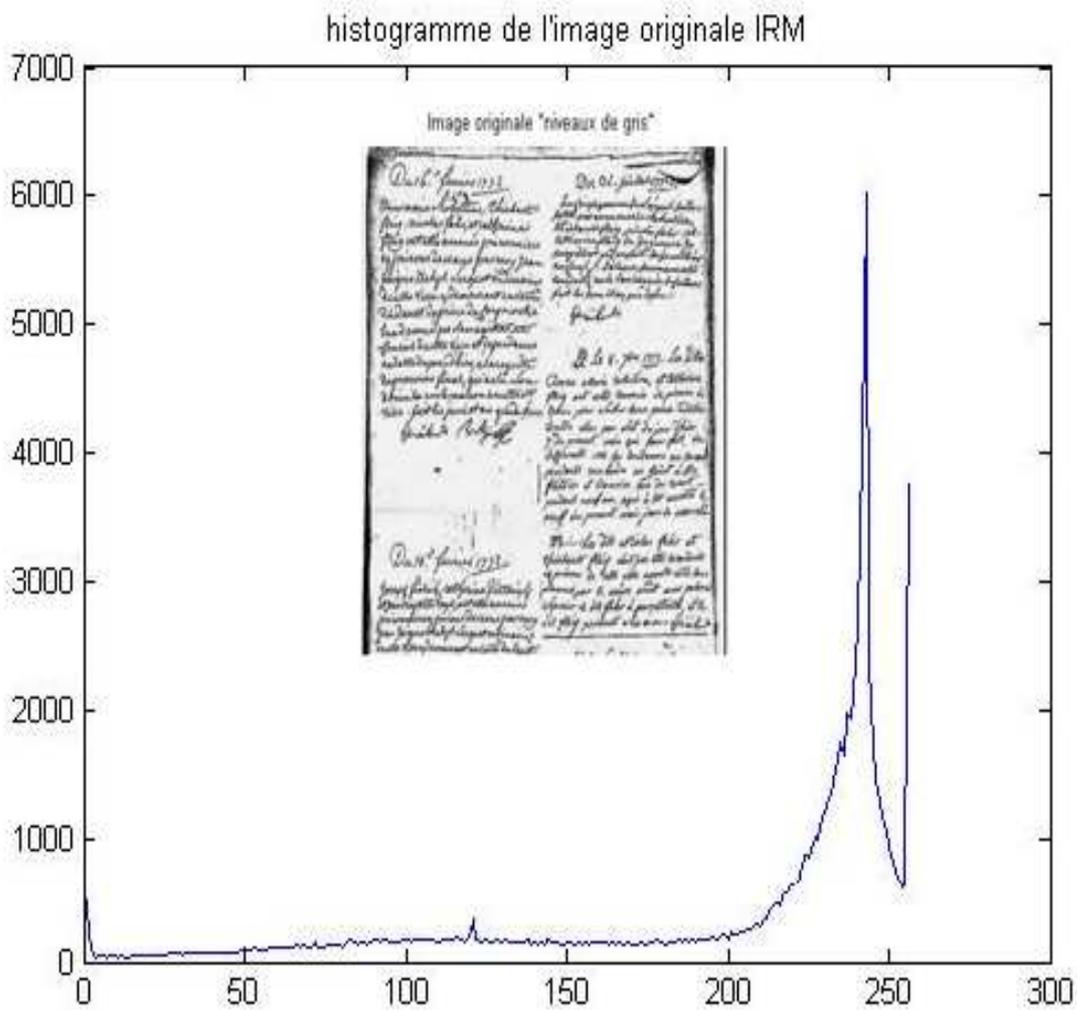


Fig.IV-5- : Image d'un ancien article et son histogramme.

Les résultats des tests sont donnés dans ce tableau suivant :

Critères de comparaison		Seuil optimal	Critère d'Uniformité	Critère de Divergence	Temps de calcul (s)
Algorithmes					
Otsu		163	0.9785	0.0878	0.0892
Huang et Wang		196	0.97333	0.097672	0.33371
Chaira et Ray		149	0.97748	0.089739	0.074718
Chang et al		127	0.97183	0.10037	0.98924
Tao et al		76	0.93758	0.14941	229.812
Liu et al		157	0.97827	0.088164	0.030017
Probabilité Non paramétrique		2	0.88693	0.2011	65.1839
La divergence floue	Bhandari et al	18	0.89585	0.19301	0.012276
	D-F-Chaira 1	149	0.97748	0.089739	0.099301
	D-F-Chaira 2	149	0.97748	0.089739	0.017737

Tableau.IV-3- Résultats des seuillages de l'image d'un ancien article.

Les images seuillées sont données comme suit :



Seuil de Liu



Seuil de diver-floue de Chaira, cas 1



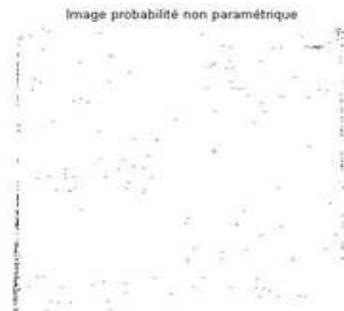
Seuil de Huang



Bhandari et al



Seuil de diver-floue de Chaira, cas 2



Seuil de proba-non-paramétrique



Seuil de Chaira



Seuil de Tao



Fig.IV-6- : Image d'un ancien article binarisée par différents seuils.

Selon les deux critères de comparaison, les méthodes de Liu et al, de Chaira et Ray et celles de divergence floue (Chaira), sont les plus performantes parmi l'ensemble des méthodes. Les seuils obtenus par ces méthodes sont plus proches à celui d'Otsu. Notons que la méthode de Bhandari et al est la plus rapide, mais reste peu efficace. Les méthodes citées précédemment ainsi que celle d'Otsu séparent bien l'écriture en noir du fond du document. Ce qui nous permet de décoder ce qu'est écrit sur l'article.

IV.4 Conclusion

Nous avons évolué dans ce chapitre quelques méthodes de seuillage flou. Cette évolution a été effectuée sur différentes images avec différents critères. Les méthodes de Chaira et Ray, de Liu et al et celle de divergence floue (Chaira) se sont avérées plus performantes que les méthodes de Tao et al, de Chang et al, de Huang et Wang, de Bhandari et al et de probabilité non paramétrique.

Dans l'ensemble des tests, la méthode de Tao et al n'est pas efficace et même son temps de calcul est très grand.

*Conclusion
Générale*

Conclusion générale

L'objectif de notre étude, est d'appliquer des techniques de seuillage flou pour la segmentation d'image floue. Le seuillage flou est basé sur plusieurs notions liées à la logique floue telles que l'algorithme FCM, l'indice flou, la mesure d'incertitude, la géométrie floue, l'entropie floue, la divergence floue et sur les mesures de probabilités.

Chaque méthode de seuillage flou, est caractérisée par un critère à optimiser. Ce critère est fonction du degré d'appartenance d'un niveau de gris à la classe (« fond » et « objet »), qui se décline sous plusieurs formes.

Nous nous sommes intéressés à la majorité des méthodes proposées dans le chapitre III, et leurs résultats sont interprétés à base de trois critères de comparaison (le degré d'uniformité, le degré de divergence et le temps de calcul). Ces méthodes ont été également comparées avec la méthode d'Otsu.

Notre effort, reste toujours dans la limite de la logique floue de type-1. Il sera très intéressant d'étendre cette étude aux méthodes de seuillages à base de la logique floue de type-2

Bibliographies

- [1] : <http://www.kaddour.com/chap1/chap1.htm>
- [2] : Nazha SELMAOUI. Traitement & Analyse d'images, 2005
- [3] : http://www.wikipedia.org/wiki/Traitement_d'images#Acquisition_d.27une_image.
- [4] : http://www.wikipedia.org/wiki/Traitement_d'images#Op.C3.A9rateurs_de_traitement_d.27images.
- [5] : http://www.wikipedia.org/wiki/Traitement_d'images#Lissage
- [6] : A.L. DAVIS. A survey of edge detection techniques. CGIP 4 pp.251-259, 1976.
- [7] : Fettouma BOUAZZA, Les contours actifs en segmentation d'images texturées, 07/07/2009.
- [8] : J.S. WESKA. A survey of threshold selection techniques, CVGIP.7, pp.259-265, 1978.
- [9] : S. WATANABE. An automated apparatus for cancer processing CYBEST, CVGIP.3, pp.350-358,1974.
- [10] : J.N. KAPUR, P.K. SAHOO and A.K.C. WONG. A new method for gray-level picture thresholding using the entropy of histogram, CVGIP.29,pp. 273-285, 1985.
- [11] : A.S. ABUTALEB. Automatic thresholding of gray-level pictures using two dimensional entropy, CVGIP 47 pp.22-32, 1989.
- [12] : N. OSTU. Threshold selection method from gray-level histogram. T-SMC-8, pp.62-66, 1978.
- [13] : Jelana Godjevac. Une idée nette sur la logique floue. COLLECTION Informatique.
- [14] : T. GADI, R. BENSLIMANE. Fuzzy hierarchical segmentation, Traitement du Signal 2000 – Volume 17 – n°1.

- [15] : Samuel Ambapour, Théorie des ensembles flous : application à la mesure de la pauvreté au Congo.
- [16] : Isabelle BLOCH, Henri MAÎTRE, Les méthodes de raisonnement dans les images, Avril 2004
- [17] : Fouad ALOUANI, Commande par Logique Floue Appliquée aux pendules inversés et au Simulateur de Vol d'Hélicoptère : Simulation et Expérimentation. 24/06/2006
- [18] : Gilla BALMISSE, La logique floue. Septembre 2002
- [19] : Thèse CHAFAA Kheireddine Structures d'identification et de commande des systèmes non linéaires basés sur les techniques floues. Université de Batna 1999.
- [20] : G.J.Klir and B. Yuan, "Fuzzy sets, Fuzzy Logic, and Fuzzy Systems". Advances in Fuzzy Systems, Application and theory, vol.6, 1996.
- [21] : 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.
- [22] : J.M. Mendel, "Computing Derivatives in Interval Type-2 Fuzzy Logic Systems", IEEE Trans. Fuzzy Syst, vol.12, no. 1, pp.84-98. 2004.
- [23] : J. M. Mendel. "Fuzzy logic systems for engineering: A tutorial", IEEE proceedings, vol. 83, 3, pp. 345-377. 1995.
- [24] : 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
- [25] : S. Philipp-Foliguet, M. B. Vieira, A. de A. Araújo, Segmentation into fuzzy regions using topographic distance, *14th SIBGRAPI*, 282-288, Florianopolis, Brazil, 2001
- [26]:E.H. Ruspini, A new approach to clustering. *Information and Control*, 15 (1), 22-32, 1969.
- [27] : R. Kara, Ph. Bolon : Une technique d'intégration des résultats de segmentation d'images, LAMII/CESALP, Université de Savoie, 1995

- [28] : Sylvie Philipp-Foliguet, Marcelo Bernardes Vieira : Segmentation d'images en régions floues, ETIS, ENSEA /UCP, Université de Cergy-Pontoise, 2000
- [29] : Sylvie Philipp-Foliguet, Marcelo Bernardes Vieira : Segmentation floue d'images couleur, ETIS, UPRESA 8051, Université de Cergy-Pontoise, 2001
- [30] : J. C. Bezdek. Pattern Recognition with fuzzy objective function algorithms. Plenum Press, New York, 1981.
- [31] : 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.
- [32] : C.V.Jawahar, P.K Biswas and A.K.Ray. Analysis of fuzzy thresholding schemes. Pattern Recognition, vol.33, pp.1339-1349, 2000.
- [33] : T. Chaira and A.K Ray. Threshold selection using fuzzy set theory. Pattern Recognition letters, vol.25, pp.865-874, 2004.
- [34] : 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.
- [35] : 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.
- [36] : SIDI MOHAMED FARSSI, Segmentation d'images par détection de région, de contour ou par morphologie mathématique étude comparative et évaluation des performances. 17juillet 1998
- [37] : H.D.Cheng, J-R. Chen and J. li. Theshold selection based on fuzzy c-partition entropy apparoach. Patten Recognition, vol.31, no.7, pp. 857-870,1998.
- [38] : 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.
- [39] : 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.

- [40] : D. Lina, Z. Jiang and. H. Feng. A novel fuzzy classification entropy approach to image thresholding. Pattern Recognition, vol.27, pp.1968-1975.
- [41] : Thèse Gilson BRAVIANO. Logique floue en segmentation d'image: seuillage par entropie et structures pyramidales irrégulières. Université Joseph Fourier- Grenoble 1. 1995.
- [42] : A. G. Shanbag, "Utilisation of information measure as a means of image thresholding". Comput. Vis. Graph. Image Process. 56, 414-419 (1994).
- [43] : Dinadundhu Bhandari, Nikhil R. Pal, and D. Dutta Majumber. Fuzzy divergence, probability measure of fuzzy events and image thresholding. Pattern Recognition Letters, (13): 857-867, 1992.
- [44] : T. Chaira and A.K Ray. Segmentation using fuzzy divergence. Pattern Recognition letters, vol.24, pp.1837-1844, 2003.
- [45] : S.K.Pal and A. Rosenfeld, "Image enhancement and thresholding by optimization of fuzzy compactness". Pattern Recogn.lett.7, 77-87 (1998).
- [46] : M.KECHIR et M.KERCHIT, Segmentation d'image basée sur la technique de seuillage flou.13/07/2010.
- [47] : Dinabandhu Bhandari, Nikhil R, Pal, and D. Dutta Majumber .Fuzzy divergence,probability measure of fuzzy event and image thresholding.pattern recognition Letters, (13)857-867,1992