

50376
1993
93

50376
1993
93



Centre d'Automatique de Lille

N° d'ordre : 1089

THESE

présentée à

L'UNIVERSITE DES SCIENCES ET TECHNOLOGIES DE LILLE

Pour obtenir le titre de

DOCTEUR

en Productique : Automatique et Informatique Industrielle

par

Marie-Claire DOUCHEZ

UTILISATION DES CONCEPTS D'ANALYSE STATISTIQUE DES DONNEES

ET DE CONNEXITE POUR LA SEGMENTATION DES IMAGES.



Soutenance prévue en mars 1993 devant le jury :



MM.

P. Vidal	Président	<i>Professeur à l'USTL</i>
J.-G. Postaire	Directeur de recherche	<i>Professeur à l'USTL</i>
J. Brémont	Rapporteur	<i>Professeur à l'Université de Nancy I</i>
G. Govaert	Rapporteur	<i>Professeur à l'Université de Technologies de Compiègne</i>
H. Deleplanque	Examineur	<i>Enseignant-Chercheur à l'Ecole des Mines de Douai</i>

AVANT PROPOS

Avant de présenter cette étude, je remercie vivement Monsieur le Professeur Pierre Vidal, Directeur du Centre d'Automatique de l'Université des Sciences et Technologies de Lille, pour m'avoir accueillie dans son laboratoire et également pour l'honneur qu'il me fait en assurant la présidence du jury de ma thèse.

J'adresse mes plus vifs remerciements à Monsieur le Professeur Jack-Gérard Postaire, directeur de recherche de l'équipe "Image et Décision" du Centre d'Automatique de Lille, grâce à qui, de par son dynamisme et son soutien constant, ce présent travail a pu aboutir. Je tiens particulièrement à le remercier pour la liberté qu'il m'a accordée pendant mes recherches, liberté sans laquelle je n'aurais pu mener à bien cette étude. Qu'il trouve ici mes plus vives reconnaissances.

Je tiens à exprimer mes vifs remerciements à Monsieur le Professeur Jacques Brémont de l'Université de Nancy I ainsi qu'à Monsieur le Professeur Gérard Govaert de l'Université de Technologies de Compiègne pour avoir accepté d'être rapporteurs de cette thèse.

Que Monsieur Henri Deleplanque, Enseignant-Chercheur à l'École des Mines de Douai, trouve ici l'expression de ma gratitude pour avoir accepté d'examiner ce travail.

Ma reconnaissance va de même aux chercheurs de l'équipe "Image et Décision" au sein de laquelle cette thèse a été réalisée ainsi qu'à mes compagnons de bureau, Gérard et Jean-Marc, pour leurs sympathies.

Pour n'oublier personne, je remercie ceux qui, de près ou de loin, en ont facilité l'aboutissement.

SOMMAIRE

Notations principales	7
-----------------------	---

- INTRODUCTION GENERALE -

<u>I LA SEGMENTATION DES IMAGES.</u>	12
<u>II LES PROBLEMES DE SEGMENTATION DES IMAGES.</u>	12
<u>III LA SEGMENTATION EN REGIONS HOMOGENES DES IMAGES PAR SEUILLAGE GLOBAL.</u>	13
<u>IV LES APPROCHES DE SEGMENTATION PAR EXTRACTION DES REGIONS.</u>	14
<u>V PLAN DE L'ETUDE.</u>	15
<u>VI CONCLUSION.</u>	16

**PREMIERE PARTIE : LES APPROCHES DE SEGMENTATION
PAR SEUILLAGE GLOBAL.**

**Chap. I - LES TECHNIQUES DE BAS NIVEAU POUR L'ELIMINATION
DES VARIATIONS SPATIALES DE L'ECLAIRAGE -**

<u>I INTRODUCTION.</u>	19
<u>II TECHNIQUE SIMPLE DE SEUILLAGE.</u>	20
II-1 Principe du seuillage global.	20
II-2 Problèmes liés à l'éclairage de l'image.	21
<u>III CONSTITUTION DE LA FONCTION LUMINANCE DE L'IMAGE.</u>	22
III-1 Formalisation mathématique.	22
III-2 Etude des variations de la composante réflectance.	22

III-3 Etude des variations de la composante illumination.	23
III-3-1 Variations chromatiques de l'éclairage.	24
III-3-2 Variations temporelles de l'éclairage.	24
III-3-3 Variations spatiales de l'éclairage.	24
IV <u>TECHNIQUES DE SEUILLAGE ADAPTATIF.</u>	26
IV-1 Définition du seuillage adaptatif.	26
IV-2 Découpage de l'image suivi d'une interpolation polynomiale.	27
IV-3 Définition des seuils par analyse du gradient des niveaux de gris.	31
V <u>TECHNIQUES DE PRETRAITEMENT D'IMAGE SOUS ECLAIRAGE NON UNIFORME.</u>	34
V-1 Principe général des techniques de prétraitement.	34
V-2 Principaux algorithmes d'approximation des variations d'illumination.	35
V-2-1 Utilisation des opérations de morphologie en niveau de gris.	35
V-2-2 Principaux algorithmes d'approximation des variations d'illumination sous une forme polynomiale.	36
V-3 Principal défaut commun aux techniques de prétraitement.	38
VI <u>TECHNIQUE SIMPLE DE MODELISATION DES VARIATIONS SPATIALES DE L'ECLAIRAGE.</u>	39
VI-1 Technique de modélisation des variations d'éclairage par une fonction polynomiale.	39
VI-2 Illustration de la méthode.	42
VII <u>TECHNIQUE ITERATIVE DE MODELISATION DES VARIATIONS SPATIALES DE L'ECLAIRAGE.</u>	48
VIII <u>CONCLUSION.</u>	53
ANNEXES.	55
<i>Annexe 1</i>	56
<i>Annexe 2</i>	58
<i>Annexe 3</i>	60
<i>Annexe 4</i>	62

**Chap. II - UTILISATION DES CONCEPTS DE L'ANALYSE STATISTIQUE DES
DONNEES POUR LA SEGMENTATION DES IMAGES -**

I <u>INTRODUCTION.</u>	66
II <u>SEGMENTATION DES IMAGES PAR CLASSIFICATION DES POINTS-IMAGES.</u>	68
II-1 Principe général de la segmentation.	68
II-2 Simplification de la procédure de segmentation.	71
II-2-1 Caractérisation monodimensionnelle des points-image.	71
II-2-2 Binarisation de l'image.	72
III <u>SEGMENTATION DES IMAGES VUE SOUS L'ANGLE DE L'ANALYSE DES DONNEES.</u>	72
III-1 Analyse statistique de l'image.	73
III-2 Règle de décision optimale.	73
III-3 Hypothèse émise sur la répartition statistique des niveaux de gris.	75
III-4 Estimation des fonctions normales de densité de probabilité.	77
III-5 Approches statistiques de classification.	79
IV <u>CONCLUSION.</u>	82

**Chap. III - UNE NOUVELLE APPROCHE D'ANALYSE STATISTIQUE
POUR LA SEGMENTATION DES IMAGES -**

I <u>INTRODUCTION.</u>	84
II <u>NOUVELLE APPROCHE D'ANALYSE STATISTIQUE POUR LA SEGMENTATION DES IMAGES.</u>	85
II-1 Classification des points-image en deux classes.	85
II-1-1 Principe de l'approche.	85
II-1-2 Résultats expérimentaux.	88
II-2 Classification multi-classe des points-image.	90
II-2-1 Principe de l'approche.	90

II-2-2 Résultats expérimentaux.	94
II-3 Approche multidimensionnelle pour la classification des points-image.	98
II-3-1 Position du problème.	99
II-3-2 Réduction de la dimension de l'espace des attributs.	99
II-3-3 Présentation d'un logiciel interactif de classification.	100
III <u>STRATEGIE UTILISEE POUR GUIDER LA CLASSIFICATION INTERACTIVE.</u>	101
III-1 Principe de l'approche.	101
III-2 Estimation de la fonction de densité de probabilité.	102
IV <u>RESULTATS EXPERIMENTAUX.</u>	105
V <u>CONCLUSION.</u>	115

**DEUXIEME PARTIE : LES APPROCHES DE SEGMENTATION
PAR EXTRACTION DES REGIONS.**

**Chap. IV - LA SEGMENTATION DES IMAGES
PAR EXTRACTION DES REGIONS -**

I <u>INTRODUCTION.</u>	119
II <u>SEGMENTATION PAR EXTRACTION DES REGIONS HOMOGENES.</u>	120
II-1 Principe fondamentaux.	120
II-2 Avantages et inconvénients.	122
II-2-1 Segmentation par divisions successives.	122
II-2-2 Segmentation par fusions successives.	125
II-2-3 Segmentation par fusions et divisions successives.	126
III <u>SEGMENTATION PAR FUSIONS SUCCESSIVES.</u>	127
III-1 Définition des régions initiales.	127
III-1-1 Recherche des facettes.	127
III-1-2 Extraction des noyaux de l'image.	129
III-1-3 Recherche des ensembles de points de propriétés semblables.	130

III-2 Fusions successives des régions initiales et intermédiaires.	131
III-2-1 Seuil de contrôle du fusionnement des régions.	131
III-2-2 Ordre de fusionnement des régions.	133
IV CONCLUSION.	134

<p>Chap. V - UNE NOUVELLE APPROCHE DE SEGMENTATION DES IMAGES PAR CROISSANCE HIERARCHIQUE DES REGIONS -</p>
--

I INTRODUCTION.	137
II PRINCIPE DE LA SEGMENTATION DES IMAGES PAR CROISSANCE HIERARCHIQUE.	137
II-1 Définition de l'homogénéité en niveau de gris d'un ensemble de points-image.	138
II-2 Définition du degré de connexité entre deux ensembles homogènes.	138
II-3 Présentation de la méthode par analyse de la connexité.	143
II-3-1 Constitution des régions initiales.	143
II-3-2 Procédure de fusionnement.	143
II-3-3 Arrêt du fusionnement.	145
III APPLICATION DE LA PROCEDURE PAR FUSIONS.	145
IV CONCLUSION.	154

<p>CONCLUSION GENERALE</p>

REFERENCES BIBLIOGRAPHIQUES	159
------------------------------------	-----

Notations principales rencontrées par ordre d'apparition.

I = image originale.

$P_n(x,y)$ / P_n = point-image de coordonnées (x,y) dans l'image.

N = nombre de points-image.

$g(P_n(x,y))$ = niveau de gris du point $P_n(x,y)$.

T = seuil global de l'image.

$B(x,y)$ = image binaire résultante de l'application sur l'image I d'une approche de seuillage global.

$b(x,y)$ = points binaires de l'image $B(x,y)$.

L / $L(x,y,\lambda,t)$ / $L(x,y)$ / $L(x)$ = fonction luminance de l'image.

λ = longueur d'onde de la lumière.

t = temps.

$I(x,y,\lambda,t)$ / $I(x,y)$ = composante illumination de la scène.

$R(x,y,\lambda,t)$ / $R(x,y)$ = composante réflectance de la scène.

$S(x,y)$ = surface de seuil adaptatif.

$t(x,y)$ = seuil adaptatif au point $P_n(x,y)$.

$B'(x,y)$ = image binaire résultante de l'application sur l'image I d'une approche de seuillage local.

$E(x)$ / $E(x,y)$ = modèle d'estimation de la composante éclairément.

$a_{i,j}$ = coefficients du modèle d'estimation $E(x,y)$.

E = erreur quadratique entre l'estimation de la composante éclairément $E(x,y)$ et la fonction luminance $L(x,y)$.

k = indice d'itération.

(I_k) = image analysée à la $k^{\text{ème}}$ itération.

(M_k) = modèle de la composante éclairément à la $k^{\text{ème}}$ itération.

(D_k) = image différence $(I_k) - (M_k)$.

(B_k) = binarisation de l'image (D_k) .

ε = constante.

Q = nombre de types de régions homogènes à identifier.

R_q = $q^{\text{ème}}$ type de régions homogènes.

x = échantillon représentatif de l'image.

X_n = observation associée au point-image P_n .

C = ensemble des classes.

C_q = $q^{\text{ème}}$ type de classes.

I_s = image segmentée.

R_{q,r_q} = $r_q^{\text{ème}}$ région de type R_q .

N_q = nombre de points appartenant aux régions de type R_q .

A = nombre d'attributs.

m_a = $a^{\text{ème}}$ attribut.

T_q = $q^{\text{ème}}$ seuil global de segmentation.

$p(g(P_n))$ = distribution des niveaux de gris des points-image.

P_q = probabilité a priori de la classe C_q .

$p(g(P_n)|q)$ = fonction de densité de probabilité associée à la classe C_q .

$p(q|g(P_n))$ = probabilité a posteriori pour que le point P_n appartienne à la classe C_q .

ε_q = erreur associée à la prise de décision.

$h(g(P_n))$ = histogramme des niveaux de gris de l'image.

μ_q = moyenne en niveau de gris des points de la classe C_q .

σ_q = variance en niveau de gris des points de la classe C_q .

T_{opt} = seuil optimal au sens de la théorie de la décision.

$\mu_q(T)$ = estimation de la moyenne en niveau de gris des points de la classe C_q .

$\sigma_q(T)$ = estimation de la variance en niveau de gris des points de la classe C_q .

g_0 = niveau de gris minimal de l'image.

g_m = niveau de gris maximal de l'image.

$C(T) / J(T) / J$ = critère de qualité du seuil T .

T^* = seuil optimal au sens du critère $J(T)$ défini.

T_q^k = $q^{\text{ème}}$ seuil à la $k^{\text{ème}}$ itération.

C_q^k = $q^{\text{ème}}$ classe à la $k^{\text{ème}}$ itération.

P_k = partition de l'histogramme à la $k^{\text{ème}}$ itération.

S_q^k = plage des niveaux de gris de la $q^{\text{ème}}$ classe à la $k^{\text{ème}}$ itération.

$J_q(T_q^k)$ = critère de qualité du seuil appliqué sur le $q^{\text{ème}}$ segment S_q^k à la $k^{\text{ème}}$ itération.

$p(X_n)$ = fonction de densité de probabilité pour l'observation X_n associée au point P_n .

$p(X_n|C_q)$ = estimation, selon un modèle normal, de la fonction de densité de probabilité pour l'observation X_n associée au point P_n .

$p(X_n)$ = estimation de la fonction densité de probabilité pour l'observation X_n associée au point P_n .

K = K plus proches voisins de l'observation X_n .

D = domaine englobant les K plus proches voisins de l'observation X_n .

$V[D]$ = volume du domaine D .

F = nombre de facettes.

$F(f)$ = $f^{\text{ème}}$ facette.

$a_{i,j}(f)$ = coefficients du modèle polynomial de la facette $F(f)$.

d = degré du modèle polynomial de la facette $F(f)$.

F_e = fenêtre définissant le voisinage de chaque point-image.

P = nombre de facettes tel que $P < F$.

μ = erreur de modélisation de l'image en facettes.

E_1, E_2 = ensembles distincts de points homogènes.

$[ndg_1, \dots, ndg_2]$ = plage des niveaux de gris des points de E_1 .

P_1 = point appartenant à l'ensemble E_1 .

P_2 = point appartenant à l'ensemble E_2 .

v -connexité = v points de E_2 voisins à un point de E_1 .

$C[E_2/E_1]$ = connexité spatiale entre les deux ensembles homogènes E_1 et E_2 .

$NB[P_1]$ = nombre de points de E_1 ayant dans leurs voisinages au moins un point P_2 appartenant à C_2 .

$D[E_2/E_1]$ = degré de connexité des points de E_2 avec ceux de E_1 .

g_i = $i^{\text{ème}}$ niveau de gris de l'image.

$E(g_i)$ = ensemble de points associé à la région initiale R_i .

g_n = niveau de gris des points les plus connexes à l'un des deux ensembles représentatifs du premier ou du second type de régions.

- INTRODUCTION GENERALE -

LA SEGMENTATION DES IMAGES

EN VISION ARTIFICIELLE.

I LA SEGMENTATION DES IMAGES.

La vision artificielle a pour but de remplacer le système biologique de perception visuelle et d'interprétation des scènes observées lors de différentes tâches habituellement remplies par des opérateurs humains. La vision artificielle regroupe le traitement, l'analyse et l'interprétation des images. La principale tâche d'un système de vision artificielle consiste à mettre en oeuvre une procédure de reconnaissance des formes afin d'identifier les différents objets composant l'image analysée.

En général, l'image comporte beaucoup trop d'informations, souvent redondantes et non essentielles, pour être analysée dans son état brut. Une représentation condensée de l'image simplifie son analyse. Un moyen efficace pour réduire l'information visuelle contenue dans une image, pour n'en conserver que l'essentiel, consiste à segmenter l'image en régions qui sont ensuite soumises à des procédures de reconnaissance des formes.

Les techniques de segmentation sont nombreuses. Elles peuvent être divisées en deux types d'approches duales. Le premier, associé à la notion de contraste, regroupe toutes les procédures de segmentation par extraction de contours [Dav-75]. A l'inverse, la seconde catégorie de procédures de segmentation des images est liée à la notion d'homogénéité [Fu-81]. Elle regroupe toutes les approches de segmentation par mise en évidence de régions homogènes.

II LES PROBLEMES DE SEGMENTATION DES IMAGES.

L'opération de seuillage global constitue l'approche la plus utilisée pour segmenter des images en niveau de gris composées de plusieurs types de régions homogènes à identifier. Bien qu'elle soit simple à mettre en oeuvre, on ne peut espérer obtenir une segmentation significative de l'image traitée que dans les cas simples où les points-image des différents types de régions occupent des plages différentes de niveaux de

gris. Bien souvent, la non uniformité de l'éclairage de la scène observée ne permet pas de vérifier cette condition. Dans ce cas, il s'avère difficile, et parfois même impossible, de choisir convenablement les seuils globaux auxquels fait appel la procédure de segmentation par seuillage.

Les approches d'extraction des contours, détectant les changements brusques d'intensité dans l'image au moyen d'opérateurs différentiels locaux, sont souvent utilisées pour remédier au problème des variations d'illumination de l'éclairage [Dav-75]. Les opérateurs différentiels ont en effet la propriété de rehausser les variations hautes fréquences des points au voisinage des contours des régions et d'atténuer les effets des fréquences basses provoquées par les variations de l'illumination produite par l'éclairage. Ils sont cependant connus pour être sensibles aux bruits de l'image de fréquences hautes [Bal-82]. Lorsque les contours détectés sont entâchés de bruit, leur extraction devient difficile et nécessite généralement des opérations gourmandes en temps de calcul. Dans ces conditions, l'opération de seuillage global peut être considérée comme une approche intéressante pour la segmentation des images, à condition toutefois de les adapter aux scènes illuminées non uniformément [Nak-79, Yan-89].

Bien qu'il soit possible de choisir pour chaque point-image un seuil dont le niveau est adapté aux conditions d'éclairage, notre étude s'inscrit dans le cadre des approches de seuillage simple qui supposent, pour leur bon fonctionnement, une uniformité parfaite de l'illumination de la scène observée. La raison de ce choix se justifie par le fait que nous proposons, en début de ce mémoire, une approche de prétraitement qui permet de rendre performante toute procédure de seuillage global sur des scènes mal éclairées.

III LA SEGMENTATION EN REGIONS HOMOGENES DES IMAGES PAR SEUILLAGE GLOBAL.

La segmentation des images par seuillage global peut être vue sous l'angle de la classification statistique des données. La théorie de la décision, appliquée au domaine de la classification statistique des données, conduit à des résultats optimaux [Dud-73, Alb-64]. Pour cette raison, elle est souvent préférée à toute autre procédure. Cette théorie repose sur une règle simple de décision. En classification, il s'agit d'assigner

chaque donnée soumise à l'analyse à la classe pour laquelle sa probabilité d'appartenance est la plus élevée. En assimilant chaque point-image à une donnée et une région homogène à une classe de points, la transcription de cette règle de décision en procédure de segmentation des images est immédiate. Cependant, son application dans un contexte supervisé nécessite une base de connaissances a priori sur l'image trop importante pour que son utilisation en segmentation soit intéressante. Plusieurs nouvelles approches de segmentation reposant sur une analyse statistique dans un contexte non supervisé ont alors été élaborées [Rid-78,Tru-79,Kit-86,Ye-88]. Elles nécessitent moins de connaissances a priori sur l'image, tout en s'efforçant d'obtenir une segmentation la plus proche possible de l'optimale.

Les techniques de segmentation opérant par classification statistique des points de l'image ont, en commun, le défaut de ne pas tenir compte de l'information spatiale existante entre les points-image constituant les régions. Or, cette information est de la toute première importance pour assurer une certaine cohésion spatiale à l'ensemble des points de chaque région homogène identifiée dans l'image. Combiner l'information statistique relevée sur les points-image avec l'information spatiale existante entre eux, telle est la perspective des procédures par extractions de régions.

IV LES APPROCHES DE SEGMENTATION PAR EXTRACTION DES REGIONS.

Plusieurs catégories d'approches par extraction sont disponibles. Il est possible de diviser l'image en régions jusqu'à ce que chacune d'elles soit homogène au sens d'un certain critère. L'ensemble des régions résultantes constitue la segmentation de l'image. Ce principe est celui suivi par les approches d'extraction par divisions successives [Wu-82]. A l'inverse, des régions de l'image peuvent être regroupées entre elles si elles possèdent des similarités d'ordre statistique. Ce cas entre dans la catégorie des procédures d'extraction par fusions successives [Zuc-76]. Les procédures de segmentation par fusions/divisions successives combinent, quant à elles, les deux approches précédentes [Hor-74].

V PLAN DE L'ETUDE.

Notre étude s'inscrit dans le cadre de la segmentation des images en régions homogènes. Nous consacrons le premier chapitre aux approches de bas niveau qui permettent, soit de segmenter une image prise dans de mauvaises conditions d'éclairage par une approche de seuillage local, soit d'améliorer la qualité d'une telle image en lui soustrayant un modèle représentatif de ses variations d'illumination. Le chapitre débouche sur une nouvelle procédure de prétraitement des images. Notre approche tire ses performances de la nature itérative de la procédure de modélisation des variations spatiales basses fréquences de l'illumination de l'image. Lorsque le modèle reflète les variations d'illumination avec une approximation suffisante, la procédure itérative de modélisation est arrêtée. Ce modèle est ensuite retranché de l'image originale afin que l'image différence soit exempte de toutes variations de luminance due aux variations spatiales de l'éclairage. Une simple procédure de seuillage global est alors applicable sur toute l'image prétraitée [Dou-90-a].

Dans le second chapitre, la segmentation des images par seuillage global est vue sous l'angle de la classification statistique des données. L'analogie entre la segmentation des images et la classification des données est établie sur la base de notions élémentaires. Après avoir établi le formalisme, plusieurs approches statistiques de classification des points-image opérant dans un contexte non supervisé sont étudiées.

Le troisième chapitre est consacré à une nouvelle approche de classification des points-image pour la segmentation des images [Dou-89,Dou-90-b]. Elle s'appuie sur l'analyse statistique de la distribution des niveaux de gris des points de l'image en vue d'identifier les différentes composantes normales qui la constituent. A l'issue de l'analyse, chaque composante normale identifiée représente la distribution statistique des niveaux de gris d'un type particulier de régions homogènes de l'image. Une extension multidimensionnelle constitue une généralisation de notre approche lorsque l'attribut niveau de gris seul ne peut permettre une discrimination suffisante des points-image.

Nous développons, dans le quatrième chapitre, les principes généraux sur lesquels reposent les approches qui utilisent conjointement l'information statistique relevée sur les points-image avec l'information spatiale existante entre-eux. Ces

approches sont communément appelées les approches par extraction des régions.

Nous concluons cette étude, par un cinquième chapitre, présentant une nouvelle procédure de segmentation par fusions [Dou-91]. Son principe consiste à identifier dans l'image des ensembles de points homogènes présentant de fortes similitudes et ayant simultanément de fortes liaisons spatiales. La notion d'homogénéité est introduite de manière simple. Un ensemble est qualifié d'homogène si tous les niveaux de gris de ses points constituent une plage continue de niveaux de gris. Le concept de connexité, permettant d'évaluer les liaisons spatiales existantes entre les points de deux ensembles homogènes, fait intervenir la notion de voisinage bien connue en traitement des images. L'objectif de l'approche consiste à regrouper le plus grand nombre de points possibles dans une même classe associée à un type de régions homogènes. Pour cela, si deux ensembles homogènes ont leurs points fortement connexes dans l'image, les points qui les constituent sont reconnus comme faisant parti d'une même région homogène. Dans ce cas, ils sont assignés à une même classe, représentative d'un type particulier de régions homogènes.

VI CONCLUSION.

Ce mémoire se décompose en deux parties. La première concerne les approches statistiques de segmentation par seuillage global tandis que la seconde concerne les approches par extraction des régions homogènes.

Dans le premier chapitre de la première partie, nous étudions les deux alternatives qui se présentent pour résoudre le problème de la segmentation des scènes illuminées non uniformément. Dans les deux chapitres suivants, les approches statistiques de seuillage sont étudiées.

Les deux chapitres de la seconde partie sont consacrés aux approches qui combinent l'information statistique et l'information locale afin de déterminer les seuils globaux de segmentation.

**PREMIERE PARTIE :
LES APPROCHES DE SEGMENTATION
PAR SEUILLAGE GLOBAL.**

**I - LES TECHNIQUES DE BAS NIVEAU
POUR L'ELIMINATION DES VARIATIONS SPATIALES
DE L'ECLAIRAGE -**

LES TECHNIQUES DE BAS NIVEAU POUR L'ELIMINATION

DES VARIATIONS SPATIALES DE L'ECLAIRAGE.

I INTRODUCTION.

Dans le domaine de la reconnaissance de formes, la phase de segmentation, qui consiste à extraire d'une image brute les informations pertinentes utiles à sa description et à l'interprétation de son contenu, est l'une des étapes les plus délicates de l'analyse des images.

Etape charnière entre le prétraitement et la reconnaissance de formes, la segmentation des images doit être menée avec le plus grand soin. En effet, toute erreur ou défaillance à ce stade de l'analyse se répercute irrémédiablement sur toute la suite des traitements, aussi sophistiqués soient-ils, ce qui conduit, par conséquent, à une mauvaise interprétation de l'image étudiée.

Les conditions de réussite d'une procédure de segmentation de l'image reposent pour une grande part sur la qualité de l'éclairage. Il nous a donc paru utile, avant toute élaboration d'une nouvelle technique de segmentation des images, d'étudier l'origine des altérations de l'uniformité de l'éclairage.

Parmi les différents types de défauts d'éclairage pouvant jouer un rôle déterminant sur la qualité de la segmentation, un type particulier se différencie des autres de par son apparition fréquente dans les scènes soumises à un éclairage artificiel. En effet, l'expérience montre qu'il est difficile de réaliser un éclairage isolux et ce, d'autant plus que la scène est de surface importante. Il en résulte un type de défaut particulier d'éclairage, qui se caractérise des variations d'illumination de type spatial, de basse fréquence. C'est l'un des rares types de défauts pour lequel on ne dispose pas véritablement de moyens matériels pour y remédier car son origine est directement liée à la géométrie des appareils utilisés pour l'éclairage de la scène observée.

Dans de telles conditions défavorables d'éclairage, le recours à des méthodes d'analyse prenant en compte ces variations s'avère nécessaire pour aboutir à une

segmentation correcte de l'image. Deux principales approches se dégagent parmi les méthodes existantes.

La première approche consiste à effectuer un prétraitement qui rend l'image apte à une segmentation par des techniques très classiques et simples, telle que le seuillage global. La seconde, quant à elle, regroupe des techniques de seuillage local adaptées aux variations spatiales, basses fréquences, de l'illumination de l'image étudiée.

L'étude de ces deux approches nous conduira à l'élaboration d'une nouvelle technique de prétraitement. Son principe consiste à estimer les variations spatiales d'illumination au travers de la scène analysée. Son efficacité résulte d'une amélioration progressive des résultats grâce à une technique d'estimation itérative. Une fois estimées les variations de l'illumination de la scène, ces dernières sont ensuite retranchées de l'image d'origine afin d'obtenir une image finale exempte des variations d'éclairage parasites. Il suffit ensuite de faire appel à une procédure de seuillage global classique pour segmenter l'image. L'ajustement des seuils globaux auxquels fait appel la procédure de seuillage est étudié dans le second chapitre.

II TECHNIQUE DE SEUILLAGE GLOBAL.

II-1 Principe du seuillage global.

Sous l'hypothèse couramment admise selon laquelle les points appartenant aux objets d'une image I occupent une plage de niveau de gris différente de celle des points du fond, il paraît naturel de les extraire de l'image par analyse de leurs niveaux de gris.

Dans ce cas idéal, selon qu'un point $P_n(x,y)$, $n=1,2,\dots,N$ de coordonnées (x,y) dans l'image, pris parmi les N points qui composent l'image, possède un niveau de gris $g(P_n(x,y))$ inférieur ou supérieur à un seuil fixe T , convenablement choisi, ce point est considéré comme appartenant ou non à l'un des objets présents dans l'image.

Cette technique simple de seuillage global ne fait appel qu'à un seuil unique T pour toute l'image. Elle conduit à une image binaire $B(x,y)$ constituée de points $b(x,y)$ dont les niveaux sont tels que :

$$b(x,y) = \begin{cases} 0 & \text{si } g(P_n(x,y)) \leq T \\ 1 & \text{si } g(P_n(x,y)) > T. \end{cases}$$

II-2 Problèmes liés à l'éclairage de l'image.

De nombreuses stratégies ont été proposées dans la littérature pour la sélection automatique du seuil global de binarisation [Sah-88,Wes-78]. Malheureusement, la scène à segmenter n'est pas toujours éclairée de manière uniforme et un seuil unique peut, dans ces conditions, s'avérer tout à fait inefficace pour l'extraction des objets.

En effet, la non uniformité de l'éclairage, dont l'origine et la nature vont être présentées dans le prochain paragraphe, peut provoquer des variations de niveaux de gris si importantes que les niveaux de gris de certains points des objets peuvent se confondre avec ceux du fond. On comprend donc pourquoi une technique de seuillage global, différenciant les points des objets de ceux du fond par comparaison de leur niveau de gris à un seuil fixe T , échouera si l'éclairage de la scène est non homogène.

L'analyse des origines des défauts d'éclairage susceptibles d'entraver le bon fonctionnement d'une technique de seuillage global fait l'objet du prochain paragraphe.

III CONSTITUTION DE LA FONCTION LUMINANCE DE L'IMAGE.

III-1 Formalisation mathématique.

De manière générale, la fonction luminance L d'une image I est le produit de la composante illumination incidente et de la composante réflectance de la scène observée.

Dans le cas le plus général, ces deux composantes sont fonction des coordonnées spatiales (x,y) des points de l'image, de la longueur d'onde λ de la lumière incidente et, éventuellement du temps t .

La fonction luminance L de l'image s'écrit donc sous sa forme la plus générale :

$$L(x,y,\lambda,t) = I(x,y,\lambda,t) \cdot R(x,y,\lambda,t).$$

où $I(x,y,\lambda,t)$ constitue la composante illumination de la scène et $R(x,y,\lambda,t)$ sa composante réflectance.

III-2 Etude des variations de la composante réflectance.

Bien que des progrès aient été accomplis dans les domaines de la synthèse d'image et de la vision artificielle [Si-85, Pen-86], la modélisation de la fonction réflectance $R(x,y,\lambda,t)$ de chaque objet présent dans l'image reste un problème délicat. En traitement des images, on a souvent l'habitude de considérer la réflectance des objets sensiblement constante, ignorant ainsi les problèmes de réflexion dus à leur nature 3D, ou des problèmes de brillance qui, il faut bien l'avouer, peuvent mettre en défaut de nombreuses procédures de segmentation.

Sous cette hypothèse simplificatrice, la fonction luminance se réduit à une expression plus simple de la forme :

$$L(x,y,\lambda,t) = I(x,y,\lambda,t).R(x,y).$$

telle que la valeur de la composante réflectance $R(x,y)$ ne dépend que de la nature intrinsèque du fond et de celle des objets présents dans l'image.

III-3 Etude des variations de la composante illumination.

Les différents types de non uniformité de l'éclairage, représentés schématiquement sur la figure I-1, peuvent être de nature chromatique, temporelle ou spatiale [Dav-86].

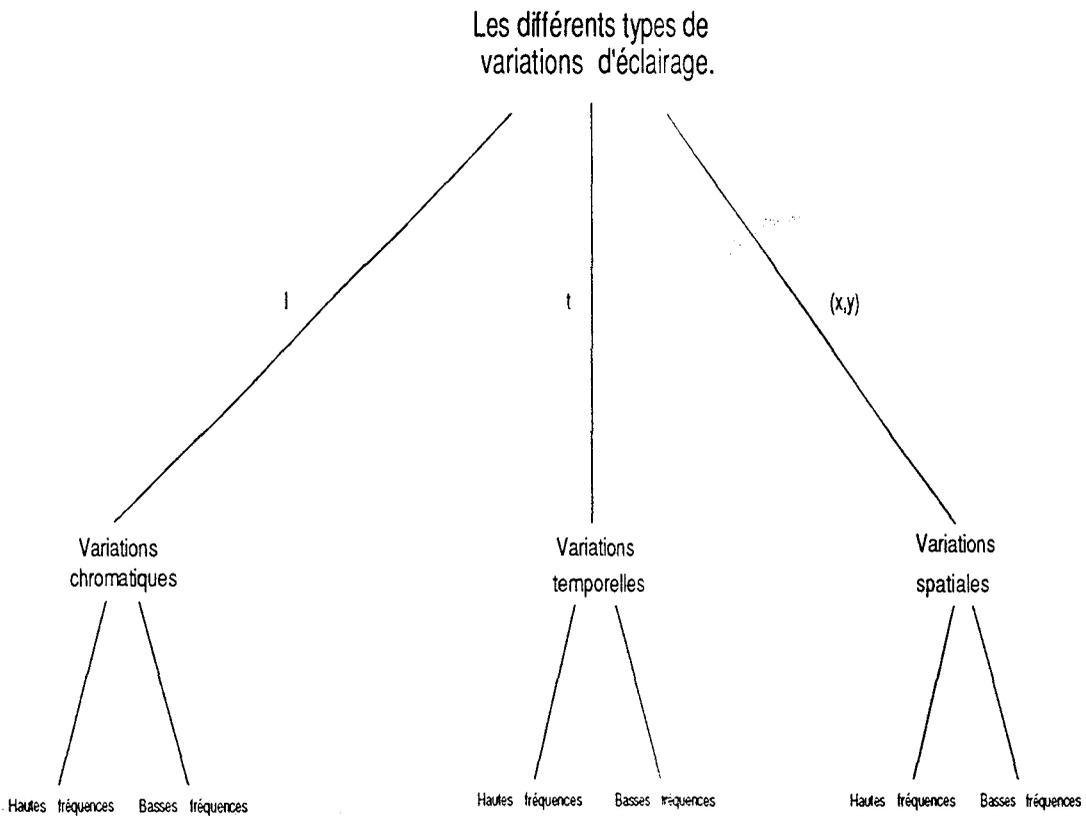


Fig. I-1 : Les différents types de variations d'éclairage.

III-3-1 Variations chromatiques de l'éclairage.

Une modification du spectre de la lumière incidente ou de celui des filtres optiques du dispositif de vision sont des exemples de variations chromatiques qui produisent, au niveau de la composante illumination $I(x,y,l,t)$ de la scène, des variations non désirées de luminance. Il s'agit cependant de modifications globales sur toute l'image dont les incidences sur les résultats des traitements peuvent être facilement contrôlées.

III-3-2 Variations temporelles de l'éclairage.

Les effets des variations temporelles de l'éclairage dépendent de la fréquence de ces fluctuations par rapport à la fréquence d'acquisition des images.

- Afin de réduire les effets des variations temporelles hautes fréquences dues par exemple à la fréquence du secteur, le système de vision doit acquérir les images avec une fréquence suffisamment basse. Cette contrainte nécessite parfois de concevoir un système d'éclairage alimenté en haute fréquence afin de pouvoir régler le temps d'intégration à une valeur admissible.

- Les variations temporelles basses fréquences représentent, quant à elles, un défaut majeur susceptible d'intervenir pour des scènes observées sous éclairage naturel, et donc fortement tributaire des conditions atmosphériques. Notons que le vieillissement des lampes fait également partie de ce type de défauts. Un objectif pourvu d'un dispositif auto-iris constitue une solution relativement efficace pour remédier à ces variations temporelles de l'illumination de la scène observée.

III-3-3 Variations spatiales de l'éclairage.

Les variations spatiales de l'éclairage peuvent, elles-aussi, être différenciés selon leurs fréquences.

- Les variations hautes fréquences, telles que les reflets de l'éclairage sur des objets métalliques, peuvent en partie être réduites en diffusant la lumière éclairant l'image.

- Les variations spatiales basses fréquences sont des défauts plus difficiles à éliminer par des moyens matériels car elles résultent de la géométrie même des appareils d'éclairage. Elles se manifestent généralement sur l'image par des dégradés de lumière néfastes pour certains traitements comme la binarisation avec un seuil global. Une lumière produite par des lampes de formes spécifiques provoque souvent un gradient spatial d'illumination de la scène observée. Par exemple, une lampe de forme sphérique délivrera une plus grande intensité au centre du cône de lumière qu'à sa périphérie. L'utilisation de réflecteurs ne permet pas, en général, de compenser totalement ces défauts d'illumination. Un jeu de sources ponctuelles ou linéaires peut compenser partiellement les défauts d'illumination qu'une seule source d'éclairage aurait provoqués sur la scène observée. Néanmoins, à l'heure actuelle, on dispose de peu de systèmes spéciaux d'éclairage qui permettent véritablement de produire une illumination parfaitement isolux d'une scène.

En conclusion, pour les raisons qui viennent d'être évoquées, il importe de porter une attention particulière aux variations spatiales basses fréquences de la fonction luminance.

Dans ce contexte, la fonction $L(x,y)$ se réduit alors à la forme :

$$L(x,y) = I(x,y).R(x,y).$$

où $I(x,y)$ représente les variations spatiales basses fréquences de l'illumination et $R(x,y)$ la composante réflectance dont la valeur dépend de la nature intrinsèque du fond et de celle des objets présents dans la scène observée.

Ainsi, dans le cadre de la segmentation d'image, lorsque les conditions d'éclairage ne se prêtent pas à une binarisation correcte par seuillage global de l'image, des techniques de seuillage adaptatif ou des techniques de prétraitement visant à corriger ce type d'imperfection du système d'éclairage doivent être utilisées.

L'étude consacrée à ces deux approches, dont l'objectif commun est de s'affranchir des effets des variations spatiales basses fréquences de la composante illumination $I(x,y)$, va être développée dans la suite de ce chapitre.

IV TECHNIQUES DE SEUILLAGE ADAPTATIF.

IV-1 Définition du seuillage adaptatif.

Lorsque la binarisation d'une image ne peut s'effectuer correctement par le choix d'un seuil global, l'utilisation d'une technique dite de seuillage adaptatif constitue la première alternative permettant de remédier aux problèmes posés par les variations spatiales basses fréquences de la composante illumination $I(x,y)$.

Cette technique consiste à construire une fonction $S(x,y)$, que nous désignons, en traduisant le vocable anglais, par "surface de seuil". Cette surface définit en chaque point $P_n(x,y)$ de l'image un seuil $t(x,y)$ dont le niveau est adapté aux conditions d'éclairage dans le voisinage immédiat du point considéré.

L'image binaire $B'(x,y)$ résultant du seuillage par cette fonction de seuil est constituée des points $b'(x,y)$ dont les niveaux sont tels que :

$$b'(x,y) = \begin{cases} 0 & \text{si } g(P_n(x,y)) \leq t(x,y) \\ 1 & \text{si } g(P_n(x,y)) > t(x,y). \end{cases}$$

Par opposition au seuillage global, cette technique de seuillage adaptatif est également appelée technique de seuillage local, puisque la valeur du seuil en chaque point dépend de sa position relative dans l'image.

Avant de développer le principe commun sur lequel reposent les approches de seuillage adaptatif, il convient de citer une approche originale de segmentation par seuillage multiple qui poursuit le même objectif [Ame-87].

Cette approche consiste à seuiller globalement l'image originale à différents niveaux. Les images binaires résultantes sont ensuite analysées sous leur aspect

morphologique afin de découvrir la forme des objets présents dans la scène par l'utilisation d'une technique statistique de reconnaissance des formes. De l'ensemble des images binaires sont alors extraits les objets de forme similaire à celle du modèle type afin de reconstituer l'image binaire attendue.

Cette méthode de seuillage multiple a été appliquée en milieu industriel [Ame-85]. Cette application montre sa robustesse vis-à-vis de la non uniformité de l'éclairage. Elle reste cependant limitée aux cas d'images comportant des objets de forme identique sans recouvrement.

Le principe commun à la plupart des approches de seuillage adaptatif consiste d'abord à définir un seuil approprié $t(x,y)$ pour certains points particuliers de l'image puis à interpoler l'ensemble de ces seuils afin de constituer globalement la surface de seuil $S(x,y)$ de l'image analysée.

Sans prétendre étudier de manière exhaustive les différentes possibilités de construction de $S(x,y)$, deux variantes possibles vont maintenant faire l'objet de notre étude.

Pour des raisons de commodité de présentation, les images utilisées pour illustrer les procédures sont des images lignes qui ne sont fonction que d'un seul paramètre x . L'extension au cas d'images bidimensionnelles se déduit directement du cas linéaire par la prise en compte de la contribution de la variable y dans le processus de modélisation de la composante éclairage.

IV-2 Découpage de l'image suivi d'une interpolation polynomiale.

Un moyen simple pour pallier les difficultés rencontrées lors de la segmentation d'images soumises à un éclairage non uniforme consiste à analyser la répartition statistique des niveaux de gris sur des zones restreintes de l'image. Ces zones sont généralement issues d'un découpage de l'image en fenêtres adjacentes de forme carrée et de même surface. L'influence de la non uniformité de l'éclairage sur le résultat de la binarisation est, en effet, moins sensible si la binarisation est appliquée sur une zone de l'image de surface suffisamment faible pour que les variations spatiales basses fréquences y soient peu prononcées.

Il serait cependant imprudent de vouloir reconstituer globalement l'image segmentée en juxtaposant les sous-images sur lesquelles une technique simple de seuillage est mise en oeuvre.

La figure I-2-a représente les niveaux de gris d'une ligne horizontale correspondant au balayage vidéo d'une image. Cette ligne est découpée en segments où figurent des seuils de binarisation. Avec ces seuils, les résultats des binarisations sur chaque segment rendent compte de l'effet de discontinuité provoqué au niveau des frontières de certains segments consécutifs, comme pour les frontières des segments L_3 - L_4 et L_5 - L_6 (fig. I-2-b).

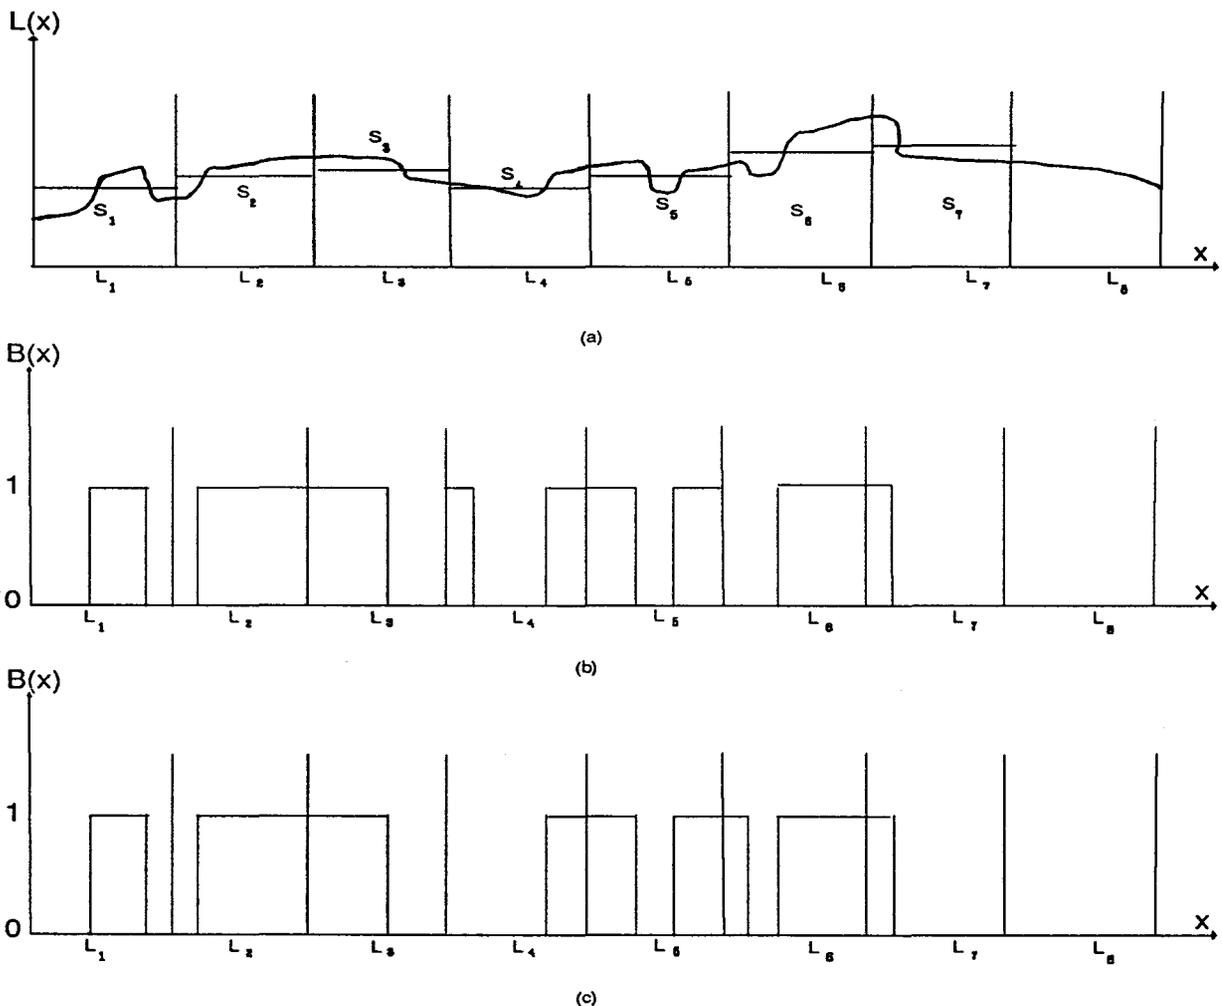


Fig. I-2: Binarisation sur des segments adjacents.

- a- Ligne vidéo découpée en segments où figurent les valeurs des différents seuils.*
- b- Binarisation obtenue .*
- c- Binarisation attendue.*

A cet inconvénient, s'ajoute celui de la présence probable de sous-images à caractère unimodal pour lesquelles il est impossible de définir un seuil.

En l'absence de seuil, comme pour le segment L_8 de notre exemple où le niveau de gris est constant, aucune décision ne peut être prise quant à l'appartenance des points au fond ou aux objets.

Pour remédier à ces deux problèmes typiques dus au découpage arbitraire de l'image, la solution proposée par Chow et Kaneko [Cho-73] est la suivante :

- Dans un premier temps, un seuil de binarisation $T_{1,2}$, dont la valeur est déduite d'une décomposition de l'histogramme des niveaux de gris analysé en composantes supposées de forme normale, est affecté au centre de chaque sous-image reconnue comme étant bimodale. Un seuil est ensuite calculé au centre de chaque sous-image unimodale par interpolation des seuils des sous-images bimodales voisines. Le second problème, relatif à l'absence de seuil, est ainsi résolu.

- Dans un second temps, une interpolation bidimensionnelle des seuils centrés sur chaque sous-image est effectuée pour le calcul du seuil $t(x,y)$ en chaque point de l'image pour obtenir la surface de seuil $S(x,y)$. Cette interpolation spatiale consiste à ajuster, sur chaque zone rectangulaire [A-B-C-D] délimitée par les points centraux A, B, C et D de 4 fenêtres adjacentes, une fonction polynomiale du premier degré $S(x,y)$. L'utilisation d'une technique d'interpolation a pour avantage d'obtenir une surface de seuil continue, évitant ainsi toute discontinuité de la binarisation le long des frontières entre les sous-images.

L'utilisation, pour la ligne vidéo de notre exemple (fig. I-3-a), de la ligne de seuil $S(x)$, déduite par interpolation linéaire des seuils affectés aux centres de chaque segment, rend compte de l'amélioration produite sur le résultat de la binarisation (fig. I-3-b).

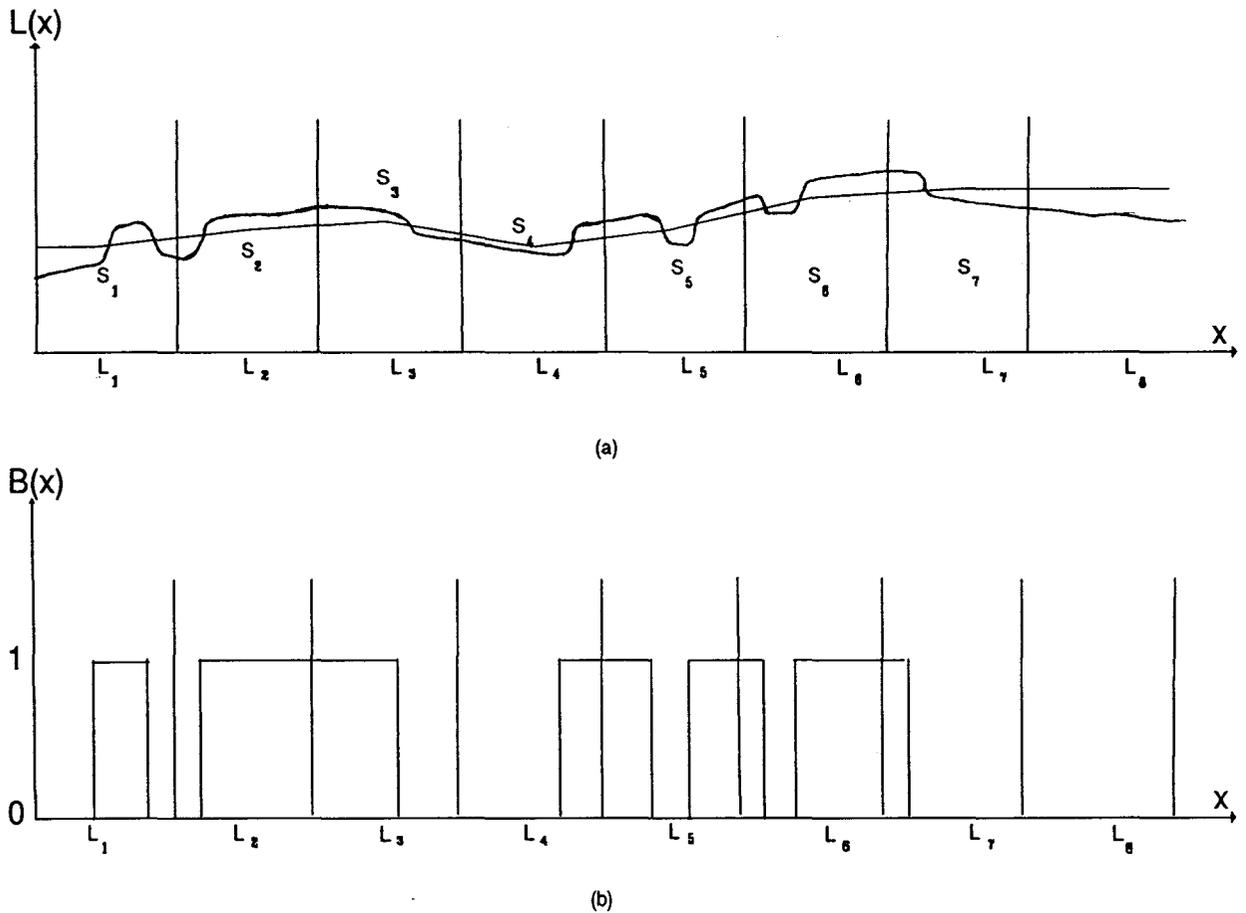


Fig. 1-3 : Principe de la technique d'interpolation.

a- Ligne de seuil déduite d'une interpolation linéaire de différents seuils.

b- Binarisation obtenue/attendue.

Cette méthode de seuillage adaptée aux variations spatiales de l'éclairage n'est pas sans poser de problèmes. Les choix de la taille et de la position des fenêtres en sont la principale cause.

L'information statistique apportée par chaque histogramme local est implicitement liée à la dimension des fenêtres. Le choix de cette dimension doit se faire judicieusement en fonction de la nature de l'image afin que l'information contenue dans chaque sous-image soit exploitable. De plus, lorsqu'un grand nombre de sous-images se trouvent localisées sur des zones homogènes de l'image, peu d'histogrammes présentent deux modes distincts. Dans ce cas défavorable, le nombre de seuils déduits de l'analyse des histogrammes est sensiblement réduit. Il en résulte une interpolation

difficile et ce, d'autant plus que les zones à histogrammes jugés unimodaux recouvrent une large surface de l'image totale.

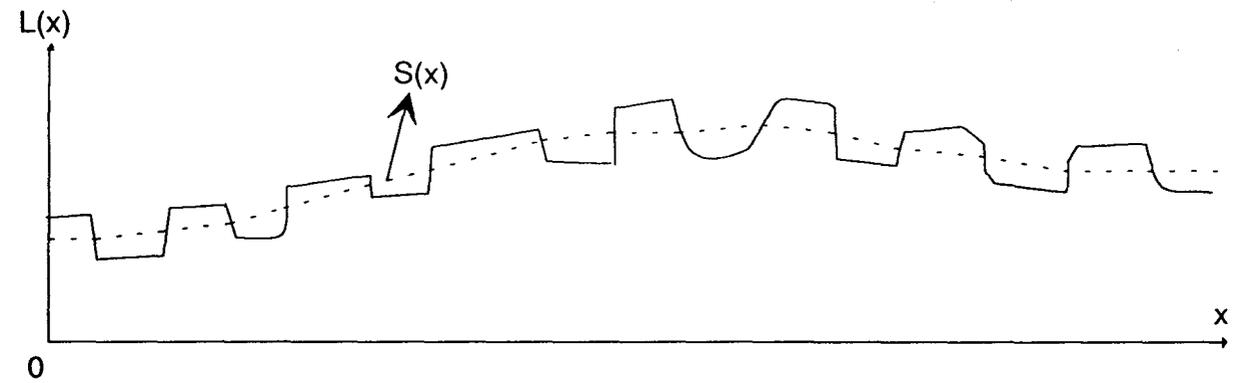
Cette approche a été étendue au cas d'histogrammes trimodaux par Y. Nakagawa et A. Rosenfeld [Nak-79]. Le même test de bimodalité, basé sur l'analyse de la variance des niveaux de gris, est appliqué sur chacune des deux paires de modes normaux consécutifs dans l'histogramme local décomposé en trois composantes normales. Lorsque les deux tests de bimodalité répondent différemment, le cas analysé se ramène à celui du cas bimodal. Dans le cas où les deux tests répondent positivement, l'histogramme est reconnu trimodal. Les deux seuils de décomposition $T_{2,3}$ et $T_{3,4}$, dont les valeurs sont déduites de la même manière que celle de $T_{1,2}$, sont alors retenus pour la segmentation. L'ensemble des seuils de même nature, à savoir les uns $T_{3,4}$ pour les régions claires et les autres $T_{2,3}$ pour les régions sombres, est ensuite interpolé pour obtenir deux surfaces de seuils, celle de type clair et celle de type sombre.

Une approche plus raffinée, proposée par Yanowitz et Bruckstein [Yan-89], consiste à tirer parti à la fois de l'information portée par la luminance des pixels mais aussi de celle fournie par les contours. Cette seconde approche originale constitue une alternative intéressante pour la construction de la surface de seuil $S(x,y)$.

IV-3 Définition des seuils par analyse du gradient des niveaux de gris.

Le principe de l'approche de Yanowitz et Bruckstein [Yan-89] a l'avantage de s'affranchir du découpage arbitraire de l'image en fenêtres, ce qui représente un atout considérable.

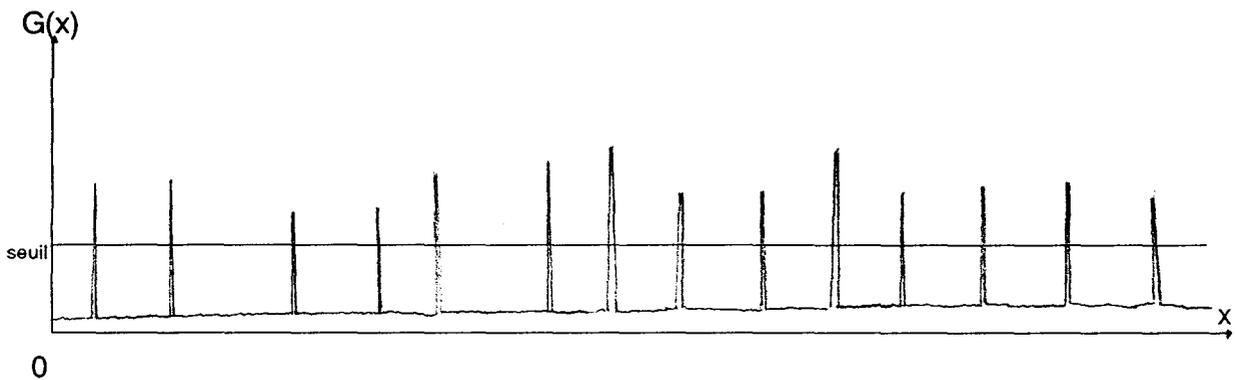
Cette approche consiste à considérer que les niveaux de gris des points pour lesquels le gradient est élevé indiquent l'existence probable de contours. Ces niveaux de gris sont donc pris comme seuils. Ces seuils sont ensuite interpolés pour obtenir la surface de seuil adaptatif $S(x,y)$ de l'image. La figure I-4 illustre ce principe d'interpolation.



(a)

x = points de gradients élevés.

$S(x)$ = ligne de seuillage adaptatif.



(b)

Fig. I-4 : Illustration de l'algorithme de seuillage adaptatif.

a- Ligne de seuil déduite par interpolation linéaire des seuils.

b- Gradient de la ligne video $L(x)$.

Cette technique de segmentation, à première vue attrayante, ne peut aboutir à des résultats significatifs que dans le cas d'images fortement contrastées où les points de contour ont un gradient marqué. De plus, l'interpolation à partir des points de gradients élevés permettant de reconstituer la surface de seuil peut être faussée lorsque la non uniformité spatiale de l'éclairage provoque une variation trop importante des niveaux de gris. La figure I-5 illustre le problème susceptible d'apparaître par cette technique de segmentation adaptative. Après interpolation des seuils sur la ligne video de cette figure, une zone de fond va être considérée comme une zone appartenant aux objets.

Ceci résulte du fait que cette zone particulière, entourée de points de gradients élevés, est soumise à d'importantes variations d'illumination.

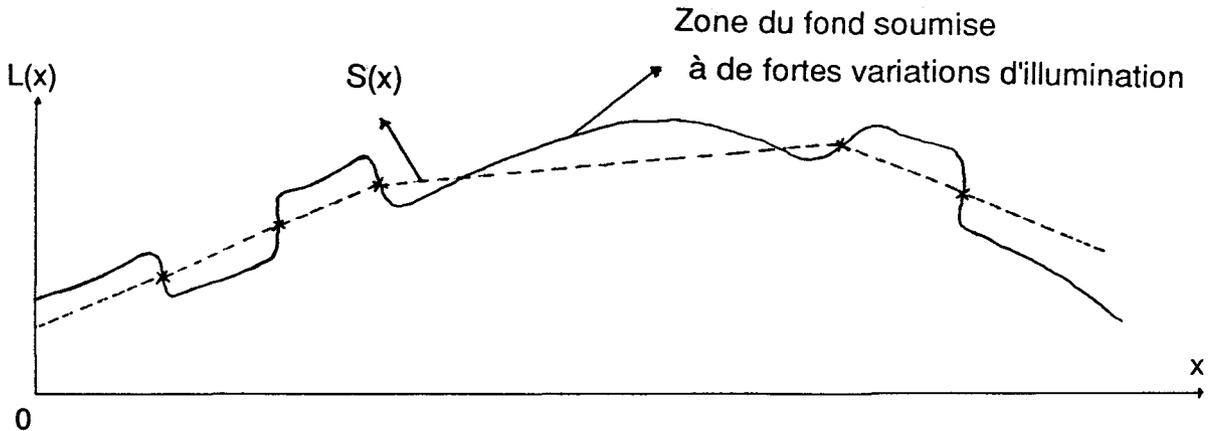


Fig. I-5 : Illustration du problème susceptible d'apparaître.

Pour résoudre ce problème, les auteurs proposent de valider le résultat final par l'emploi de la technique "Superslice".

Cette approche, décrite dans [Mil-78], permet de valider l'existence des objets mis en évidence dans l'image seuillée. Si, pour un objet particulier extrait, la moyenne du gradient de ses points de contours n'est pas suffisamment élevée pour prouver son existence, l'objet est considéré comme incorrectement seuillé. Cet objet n'est alors pas reconnu comme un objet réel de l'image.

L'objectif commun à toutes les techniques présentées jusqu'ici consiste à segmenter l'image point par point par un seuil dont le niveau s'adapte aux variations locales de l'éclairage. Il existe une seconde catégorie de techniques, dite de prétraitement, qui permet d'améliorer les images afin de pouvoir leur appliquer des procédures de segmentation par seuillage global malgré la présence des variations spatiales d'illumination de l'éclairage.

V TECHNIQUES DE PRETRAITEMENT DES IMAGES SOUS ECLAIRAGE NON UNIFORME.

Les procédures de prétraitement considérées ici visent à améliorer l'image afin de rendre sa segmentation plus aisée. Cette amélioration peut consister à éliminer le bruit [Kra-75,Wan-83], à augmenter le contraste [Ros-85] ou, comme nous allons le voir dans le cadre de notre étude, elle peut permettre de s'affranchir des variations spatiales basses fréquences de l'éclairage, néfastes à tout processus de segmentation par seuillage global.

V-1 Principe général des techniques de prétraitement.

Pour des raisons évoquées en début de ce chapitre, l'étude des variations spatiales de la fonction luminance observée se ramène à celle des variations spatiales basses fréquence intervenant au niveau de la composante illumination.

Or, pour beaucoup d'images, l'aspect du fond est homogène et cette propriété peut être généralement mise à profit pour résoudre les problèmes liés à la non-uniformité de l'éclairage.

En effet, un fond homogène se caractérise par une réflectance $R(x,y)$ constante. De ce fait, toute variation du niveau de gris des points du fond reflète une variation de la composante illumination incidente $I(x,y)$.

Le principe du prétraitement consiste à estimer les variations de luminance des points du fond de l'image qui reflètent les variations spatiales de type basse fréquence de l'éclairage.

Soit $E(x,y)$ l'approximation de ces variations, appelée "composante éclairage". La soustraction de cette composante à la fonction image elle-même $L(x,y)$ rend possible l'application d'une méthode de seuillage global sur les niveaux de gris résultants. En effet, l'image se trouve, par cette approche, dépourvue de toutes les variations lumineuses induites par le dispositif d'éclairage.

V-2 Principaux algorithmes d'approximation des variations d'illumination.

V-2-1 Utilisation des opérations de morphologie en niveau de gris.

Notons que les opérations de morphologie en niveau de gris s'emploient dans le cadre de la segmentation d'images éclairées non uniformément. Le principe de base consiste à extraire de l'image d'origine, par application d'outils morphologiques, l'image représentative des variations spatiales basses fréquences de l'éclairage. Cette image est ensuite soustraite de l'image d'origine afin d'obtenir une image différence exempte de toute variation d'illumination.

Dans [Dau-89], les auteurs proposent d'utiliser les deux principales opérations de morphologie, qui sont l'ouverture et la fermeture, pour mener à bien cette procédure. Les pics de niveau de gris sont assimilés à du bruit tandis que les objets, supposés de niveaux de gris plus faibles que le fond de l'image, correspondent à des creux de la fonction $L(x,y)$.

L'ouverture est une opération morphologique qui a pour effet de réduire les pics dans l'image et à l'inverse, l'opération de fermeture conduit à combler les creux.

Dans un premier temps, les auteurs de cette approche appliquent sur l'image d'origine une opération d'ouverture afin de réduire le bruit de l'image. Cette première opération est ensuite suivie d'une opération de fermeture afin de reconstruire l'image représentative des variations de l'éclairage. Cette seconde opération consiste à remplacer les niveaux de gris des points des objets par des niveaux proches de ceux des points voisins appartenant au fond dont les variations reflètent celles de l'éclairage.

Bien que cette méthode donne des résultats intéressants, elle ne peut être utilisée que lorsque la forme et la taille des objets sont connus. L'érosion morphologique conduit, en effet, à éliminer toute forme dans l'image plus petite que l'élément structurant utilisé. Si le résultat recherché consiste à éliminer les objets de l'image, l'élément structurant doit être choisi de manière appropriée, c'est à dire proche de la forme des objets à éliminer. Cette tâche n'est pas toujours évidente face à des images dont on ne connaît pas le contenu a priori.

Les variations lumineuses de l'éclairage peuvent également être modélisées sous la forme d'une fonction analytique, prise usuellement sous une forme polynomiale bidimensionnelle dont le degré, relativement faible, a pour avantage de lisser les variations dues au bruit de l'image [Hel-83].

V-2-2 Principaux algorithmes d'approximation des variations d'illumination sous une forme polynomiale.

Pour des raisons de commodité de présentation, les images utilisées pour illustrer les procédures sont des images lignes qui ne sont fonction que d'un seul paramètre x . L'extension au cas d'images bidimensionnelles se déduit directement du cas linéaire par la prise en compte de la contribution de la variable y dans le processus de modélisation de la composante éclairage.

a) Modélisation des variations d'illumination par une fonction polynomiale de degré égal à un.

Analysons la luminance de l'image ligne de la figure I-6 sur laquelle le niveau de gris moyen augmente progressivement d'un bout à l'autre de la ligne. Ce type de variation, dont la cause la plus courante est l'asymétrie géométrique de la source d'éclairage, peut être estimé en recherchant l'équation de la droite $E(x)$ selon une technique classique de type moindres carrés.

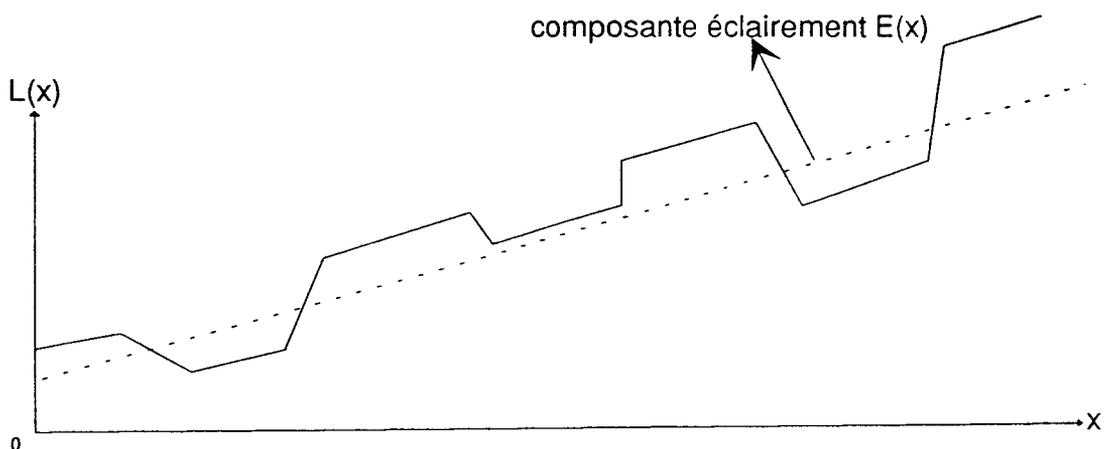


Fig. I-6 : Luminance d'une ligne avant traitement.

Une fois la composante éclairage $E(x)$ modélisée, cette-ci est retranchée du signal vidéo $L(x)$, comme sur la figure I-7. Une valeur constante C est ajoutée au signal résultant afin que le tout puisse représenter une ligne vidéo dont tous les niveaux de gris sont positifs.

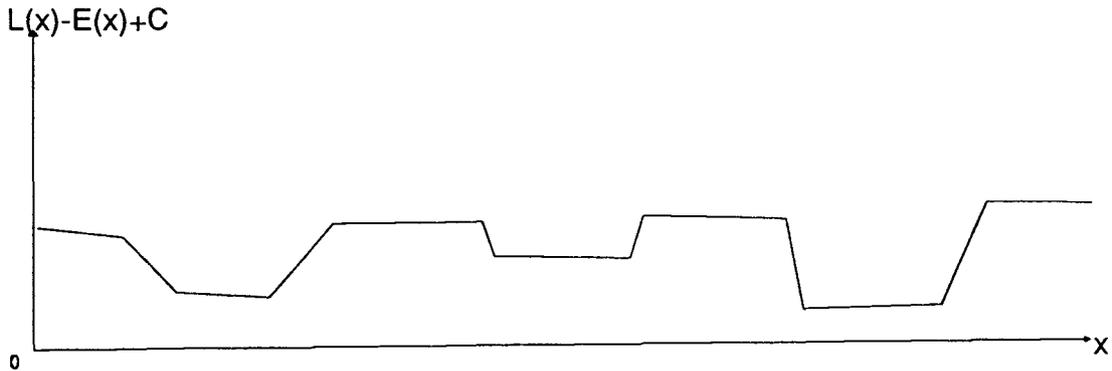


Fig. I-7 : Luminance de la ligne après traitement.

Pour des images bidimensionnelles, le plan constitue le modèle le plus simple pour modéliser les variations d'éclairage de l'image. L'expression mathématique du modèle plan s'écrit de la façon suivante :

$$E(x,y) = a_{0,0} + a_{0,1} \cdot x + a_{1,0} \cdot y + a_{1,1} \cdot x \cdot y.$$

Cette modélisation peut se faire sur l'image entière ou sur un ensemble de zones de tailles plus petites.

b) Modélisation des variations d'illumination par une fonction polynomiale de degré supérieur à un.

Il n'est pas toujours possible de modéliser les variations d'illumination par une fonction polynomiale de degré unitaire. Il se peut, en effet, que les variations spatiales de l'éclairage aient une forme plus complexe, surtout si le champ observé par la caméra est étendu.

Dans ces conditions, le choix d'un modèle analytique polynomial de degré supérieur à un apporte une solution efficace à l'estimation des variations spatiales d'éclairage de forme plus complexe.

Dans le cas monodimensionnel, le modèle polynomial $E(x)$ se présente sous la forme :

$$E(x) = a_0 + a_1 \cdot x + \dots + a_d \cdot x^d.$$

où a_0, a_1, \dots, a_d sont les coefficients d'un polynôme de degré d .

Dans le cas bidimensionnel, la composante illumination est modélisée par un modèle polynomial de degré d dont l'écriture se présente comme suit :

$$E(x,y) = a_{0,0} + a_{0,1} \cdot x + a_{0,2} \cdot x^2 + \dots + a_{d-1,1} \cdot x \cdot y^{d-1} + a_{d,0} \cdot y^d.$$

L'extension de la modélisation polynomiale monodimensionnelle au cas bidimensionnel aboutit à un prétraitement efficace d'images pour lesquelles les variations d'éclairage ont une forme relativement complexe [Del-87]. Cette modélisation fait l'objet du paragraphe VI.

V-3 Principal défaut commun aux techniques de prétraitement.

Rappelons que toutes les techniques de prétraitement qui viennent d'être évoquées visent à retrancher de l'image originale les variations d'éclairage approchées à partir de la prise en compte des niveaux de gris du fond.

Or, ne disposant a priori d'aucune information sur la provenance des points de l'image, l'évaluation des paramètres de la fonction analytique servant de modèle aux variations d'éclairage peut être entachée d'erreurs si un nombre trop important de points appartenant aux objets sont pris en compte dans le processus de modélisation. La segmentation par seuillage global est alors rendue impossible sur l'image prétraitée car le modèle ne reflète pas fidèlement la composante illumination.

Puisque la qualité de la modélisation de l'éclairage est fonction du nombre de points provenant du fond qui interviennent effectivement dans le processus de modélisation, la procédure ne pourra être mise en oeuvre avec succès que si la surface occupée par les objets est faible vis-à-vis de la surface totale de l'image.

Le rôle décisif que joue la surface des objets sur la qualité de la modélisation des variations spatiales d'éclairage nous a amenés à nous pencher plus particulièrement sur ce problème délicat et nous a conduits à élaborer une approche itérative issue de ce principe simple de modélisation.

VI TECHNIQUE SIMPLE DE MODELISATION DES VARIATIONS SPATIALES DE L'ECLAIRAGE.

VI-1 Technique de modélisation des variations d'éclairage par une fonction polynomiale.

Sous l'hypothèse où le fond uniforme de l'image reflète les variations lumineuses de l'éclairage de la scène observée, hypothèse dont la justification a été établie au début de ce chapitre, le principe consiste à approcher les variations spatiales de l'éclairage à partir de l'analyse des niveaux de gris des points du fond.

Nous avons vu que le modèle polynomial est souvent choisi de la forme :

$$E(x,y) = a_{0,0} + a_{0,1} \cdot x + a_{0,2} \cdot x^2 + \dots + a_{d-1,1} \cdot x \cdot y^{d-1} + a_{d,0} \cdot y^d.$$

ou encore sous une forme plus compacte :

$$E(x,y) = \sum_{r=0}^d \sum_{s=0}^r a_{r-s,r} \cdot x^s \cdot y^{r-s}$$

Ce choix se justifie par le fait qu'en jouant sur le paramètre d , on peut modéliser des types de surfaces très variés. L'estimation des coefficients $a_{i,j}$ avec $i = 0, \dots, d$ et $j = 0, \dots, d$ par la technique des moindres carrés consiste à minimiser l'erreur quadratique E entre $E(x,y)$ et les niveaux de gris $L(x,y)$ des points du fond de l'image :

$$E = \sum_{(x,y) \in \text{fond}} [E(x,y) - L(x,y)]^2.$$

L'annulation des dérivées partielles de cette erreur quadratique en fonction des coefficients $a_{i,j}$ du polynôme $E(x,y)$ permet d'aboutir à un système d'équations linéaires qui, après résolution, donnerait les coefficients optimaux du modèle polynomial des variations spatiales de l'éclairage.

Or, ne pouvant différencier les points de l'image appartenant au fond de ceux provenant des objets, cette erreur est donc calculée sur l'ensemble des points de l'image :

$$E = \sum_{(x,y) \in \text{image}} [E(x,y) - L(x,y)]^2$$

D'un point de vue algorithmique, afin d'accélérer la détermination des coefficients du modèle, ceux-ci sont estimés non pas à partir de tous les points de l'image mais de ceux appartenant à un maillage lâche défini sur l'image. Ce maillage, présenté sur la figure 1-8, est défini en choisissant un pas d'échantillonnage adéquat p égal au nombre de pixels séparant 2 points du maillage sur une même ligne. Deux lignes consécutives du maillage sont également séparées par le même nombre p de pixels.

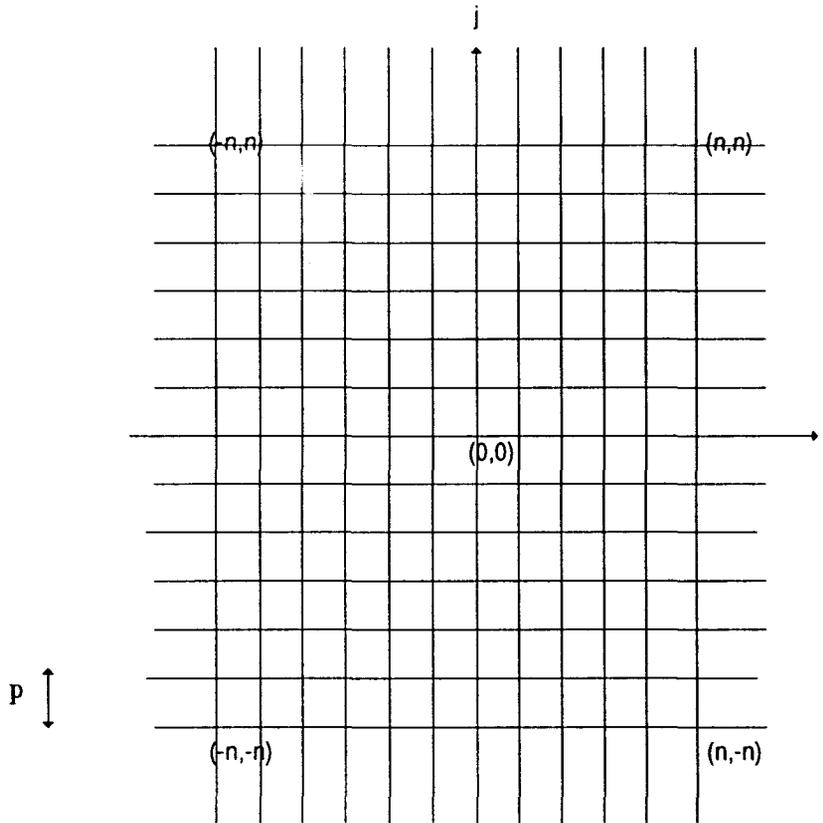


Fig. I-8 : Maillage de l'image.

L'erreur quadratique s'écrit donc :

$$E = \sum_{(x,y) \in \text{maillage}} [E(x,y) - L(x,y)]^2$$

ou, plus explicitement :

$$E = \sum_{i=-n}^n \sum_{j=-n}^n [E(i,j) - L(i,j)]^2 .$$

Pour plus de précision en ce qui concerne la résolution du système d'équations linéaires établi à l'ordre général en annexe I, se référer aux annexes II et III relatives aux polynome de degrés 2 et 3, respectivement.

Quant au choix du degré d du modèle polynomial, il doit se faire selon la complexité des variations lumineuses d'éclairage affectant la composante illumination de la scène observée.

Il faut cependant signaler que les variations spatiales d'éclairage prises en compte sont celles de type basses fréquences. Un modèle de degré 1 ou 2 se prête généralement bien pour la modélisation de ces variations d'éclairage. Le degré 3 n'est que rarement utilisé car il n'est utile que pour des variations plus complexes que l'on ne rencontre que dans des conditions d'éclairage défaillantes pour des champs de vision de taille importante.

VI-2 Illustration de la méthode.

Pour analyser le comportement de la procédure de modélisation des variations d'éclairage proposée, on utilise une image composée de clés disposées sur un fond uniforme. Cette image (I_0) a été acquise dans des conditions très défavorables d'éclairage (figure I-9). Il est à noter que la surface des objets, c'est à dire celle des clés, recouvre une surface non négligeable de l'image.

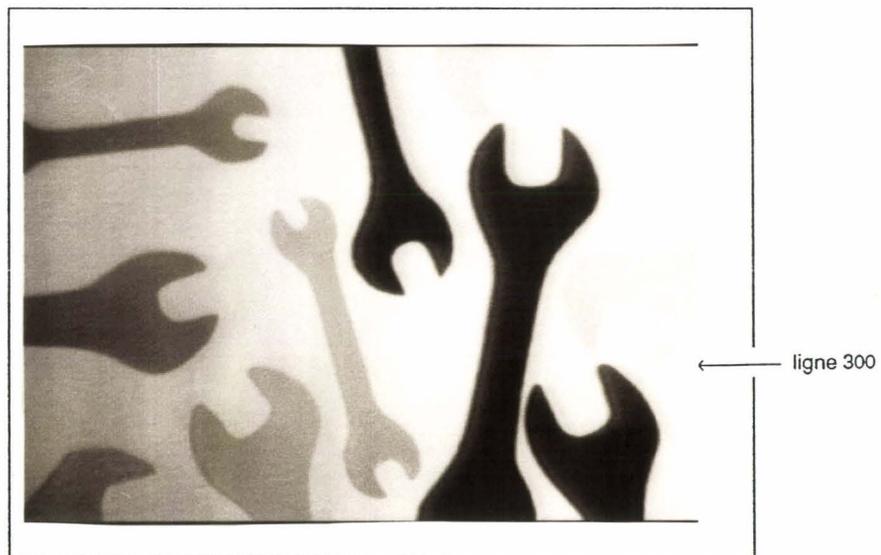
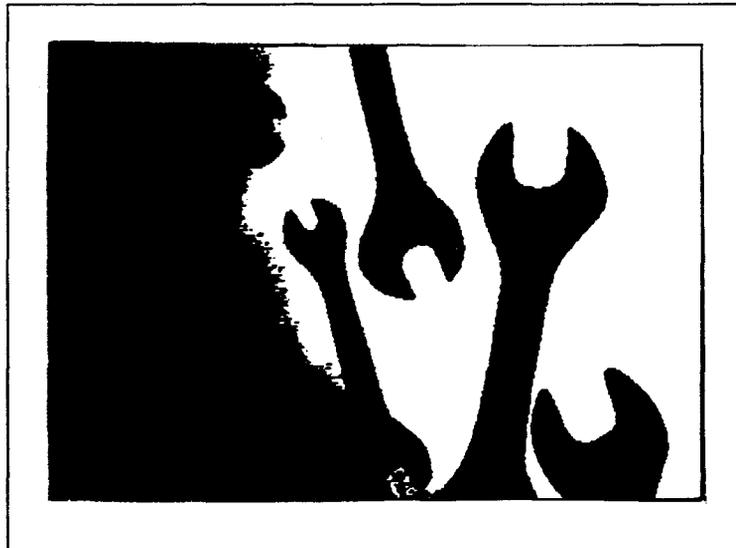


Fig. I-9 : Image originale (I_0).

La binarisation à un seuil fixe ne permet pas d'extraire les objets de leur fond. Les figures I-10-a et I-10-b montrent les résultats médiocres de la binarisation de l'image pour 2 seuils globaux.



(a)



(b)

Fig. I-10 : Binarisations de l'image (I_0).

a- Au seuil $T= 40$.

b- Au seuil $T= 60$.

Puisqu'aucun seuil ne permet de séparer correctement les clés de leur fond, il convient de modéliser les variations de l'illumination afin de les soustraire de l'image pour la rendre apte au seuillage global.

En analysant une coupe de cette image (figure I-11), on s'aperçoit que les variations d'éclairage présentent une forme relativement complexe. Un modèle de degré 3 s'impose donc.

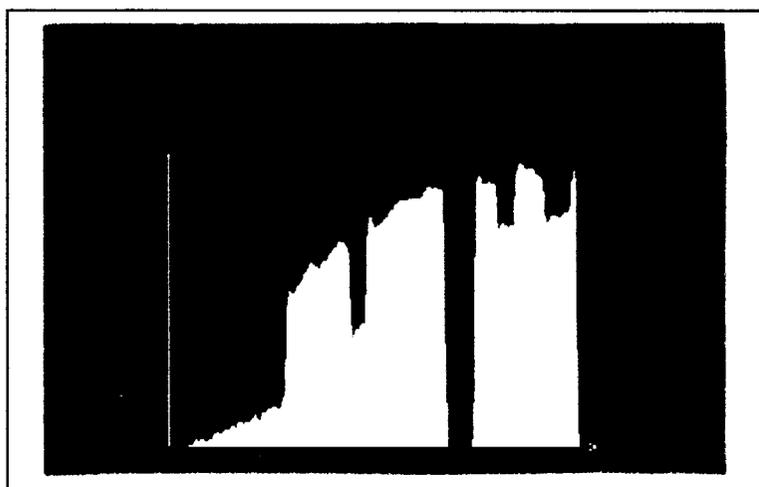


Fig. I-11 : Luminance de la ligne 300 de (I_0) .

Le modèle analytique $E(x,y)$ utilisé s'écrit alors sous la forme :

$$E(x,y) = a_{0,0} + a_{0,1}.x + a_{0,2}.x^2 + a_{0,3}.x^3 + a_{1,0}.y + a_{1,1}.x.y + a_{1,2}.x^2.y + a_{2,0}.y^2 + a_{2,1}.x.y^2 + a_{3,0}.y^3 .$$

Les coefficients optimaux du modèle $E(x,y)$ des variations d'éclairage sont évalués en minimisant l'erreur quadratique E , entre le modèle $E(x,y)$ et la fonction de niveau de gris $L(x,y)$, sur un maillage couvrant toute l'image, avec un pas d'échantillonnage pris égal à cinq.

Le modèle (M_0) approchant les variations d'éclairage représenté sur la figure I-12 est obtenu en évaluant la composante éclairage $E(x,y)$ dans laquelle chaque coefficient a été remplacé par sa valeur optimale en tous les points du plan image.

Ce modèle (M_0) est finalement retranché de l'image initiale (I_0) afin d'obtenir une image (I_1) où la composante illumination apparaît plus uniforme (fig. I-13).

Lorsqu'un seuillage global est effectué sur l'image résultante (I_1), on s'aperçoit, sur l'image binarisée (B_1) que seule une partie des objets de l'image (I_0) peut être correctement extraite (fig. I-14). En effet, une binarisation de l'image à un seuil plus élevé échoue puisque l'étiquetage résultant ne permet pas de différencier convenablement les points des objets de ceux du fond (fig. I-15).

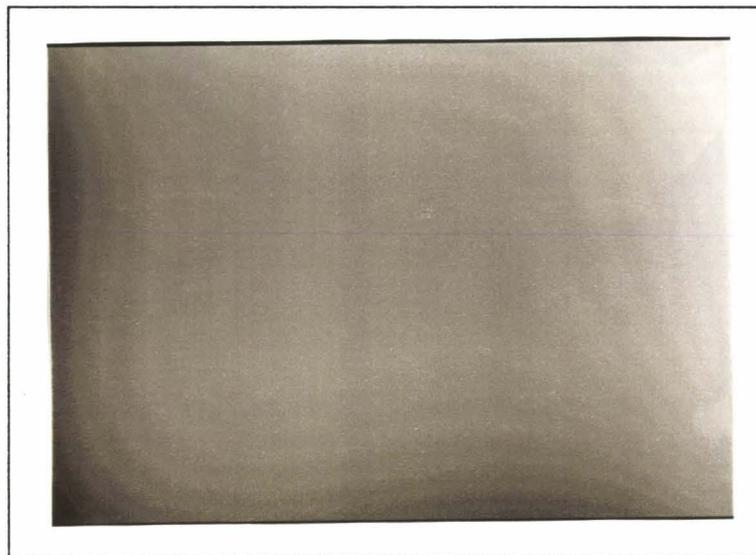


Fig. I-12 : Modélisation (M_0) de l'image (I_0).



Fig. I-13 : Image différence $(I_1) = (I_0) - (M_0)$.

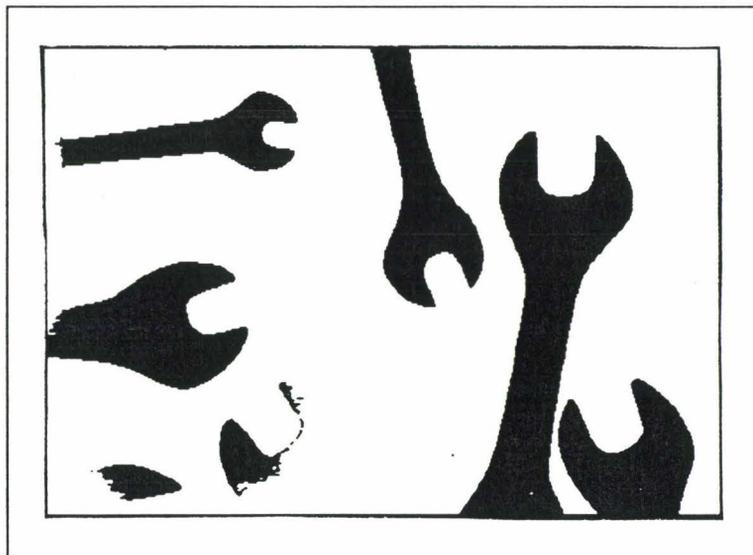


Fig. I-14 : Image binarisée (B_1) de (I_1) .

VII TECHNIQUE ITERATIVE DE MO L'ECLAIRAGE.

L'itération du processus simple va permettre d'obtenir, de proche variations lumineuses spatiales de l'é

Ce principe, illustré sur la même

Nous venons de voir que, bien soit éloigné des variations réelle initiale (I_0), on obtient une image impossible à binariser correctement par binarisation par seuillage global (présents dans l'image).

Une nouvelle approximation calculée à partir de l'image (D_1) (fi de (B_1) à l'étape précédente ont été dans le premier modèle (M_0), plus

Une différence entre le modèle d'obtenir une image (I_2) (fig. I-18) partie des objets (B_2) (fig. I-19).

En comparant l'image binaire les objets sont mieux extraits, par s

Ceci s'explique par le fait que l'image (I_0) pour laquelle les pixels diffèrent du fond. On suppose que reflètent celles des variations d'illum la modélisation polynomiale de l'in en (B_1) ont été remplacés par u d'éclairage que ne l'est leur n représentatif des variations réelles



Fig. I-15 : Image binaire (B) de (I_1).

L'impossibilité d'extraire la totalité des objets de l'image rend compte des limites de ce principe de prétraitement. Les résultats insuffisants du prétraitement pour ce type d'image sont dus à la contribution inévitable des points des objets de surface importante dans le processus de modélisation des variations de l'éclairage dont le modèle (M_0) demeure éloigné des variations réelles de l'éclairage.

La soustraction du modèle (M_0) des variations d'éclairage de l'image d'origine ne peut, par conséquent, aboutir à une image différence exempte de toute variation lumineuse spatiale de basses fréquences. Les défauts d'éclairage persistants rendent inapte l'image prétraitée à une segmentation par seuillage fixe.

En conclusion, cette méthode simple de prétraitement conduit à des résultats d'autant plus satisfaisants que la surface occupée par le fond est prépondérante sur celle occupée par les objets. L'amélioration que nous allons apporter à cette technique simple de prétraitement permet d'étendre son utilisation à des images où les objets occupent une surface importante.

Il en résulte que les variations lumineuses d'éclairage sont moins prononcées dans l'image différence (I_2) que dans l'image différence (I_1) .



Fig. I-16 : Image (D_1).

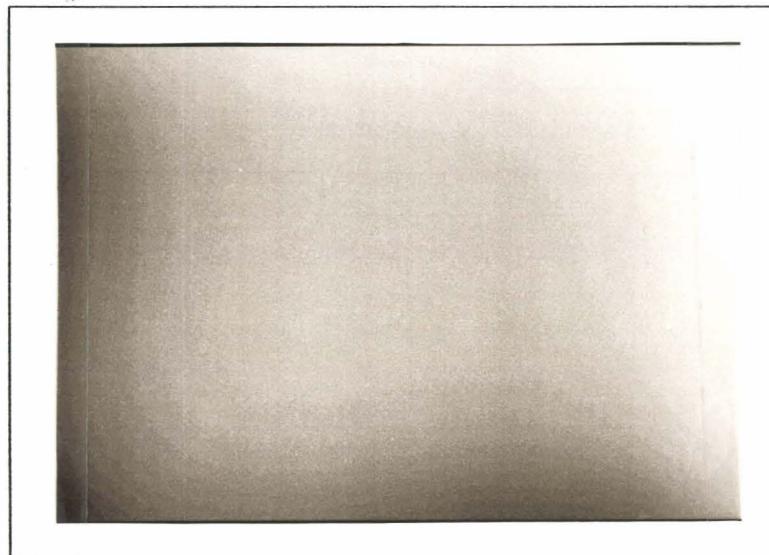


Fig. I-17 : Modélisation (M_1) de l'image (D_1).



Fig. I-18 : Image différence (I_2)= (M_1) - (I_0).

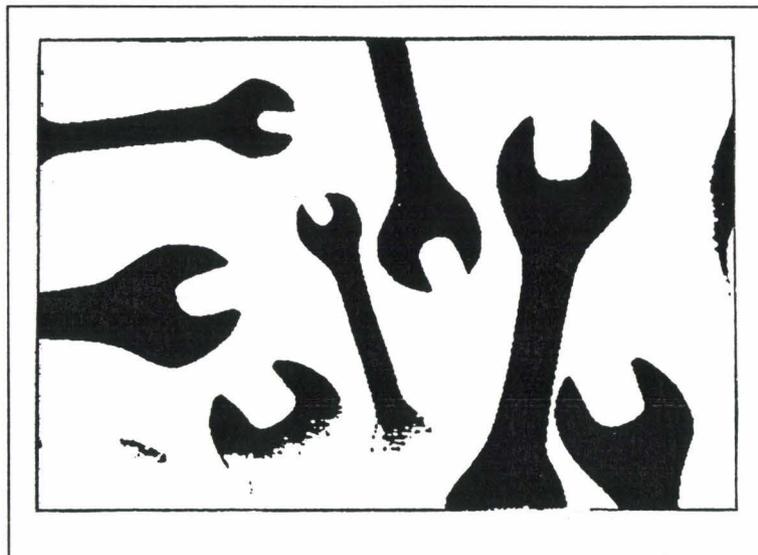


Fig. I-19 : Binarisation (B_2) de (I_2).

L'itération du processus de modélisation permet donc d'obtenir de proche en proche un modèle plus représentatif des variations réelles de l'éclairage puisqu'à chaque itération du procédé un nombre plus important de points des objets sont remplacés par un niveau de gris de plus en plus proche de la luminance du fond.

L'itération du procédé est arrêtée par un test portant sur l'écart des coefficients entre deux itérations successives, c'est à dire lorsque les coefficients $a_{i,j}^{(k)}$ et $a_{i,j}^{(k+1)}$ entre deux itérations successives de rang k et $k+1$ vérifient la relation :

$$\left| \frac{a_{i,j}^{(k)} - a_{i,j}^{(k+1)}}{a_{i,j}^{(k+1)}} \right| < \varepsilon$$

où ε est une constante, choisie en fonction de la finesse de la modélisation recherchée.

L'évolution des coefficients du modèle polynomial de la composante éclairage figure dans l'annexe IV de ce chapitre.

La figure I-20 qui représente les images binarisées successives obtenues (Images (B_i) pour $i = 1, \dots, 7$) nous montre l'amélioration qu'apporte l'itération de la modélisation des variations lumineuses de l'éclairage. L'ajustement du seuil global auquel fait appel chaque binarisation est étudié dans le second chapitre.

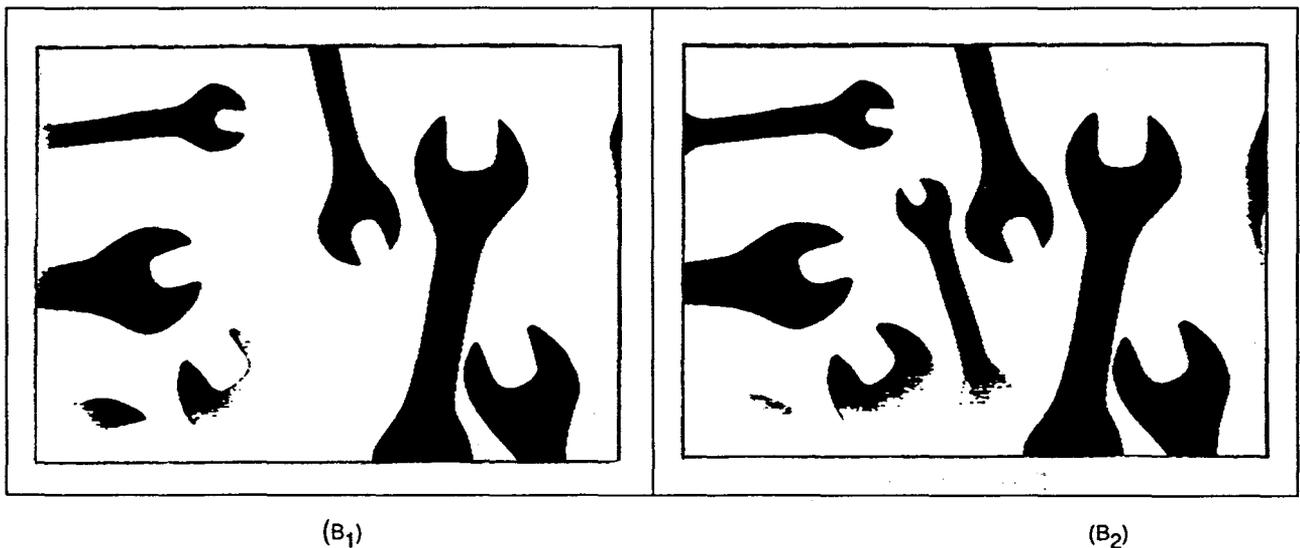
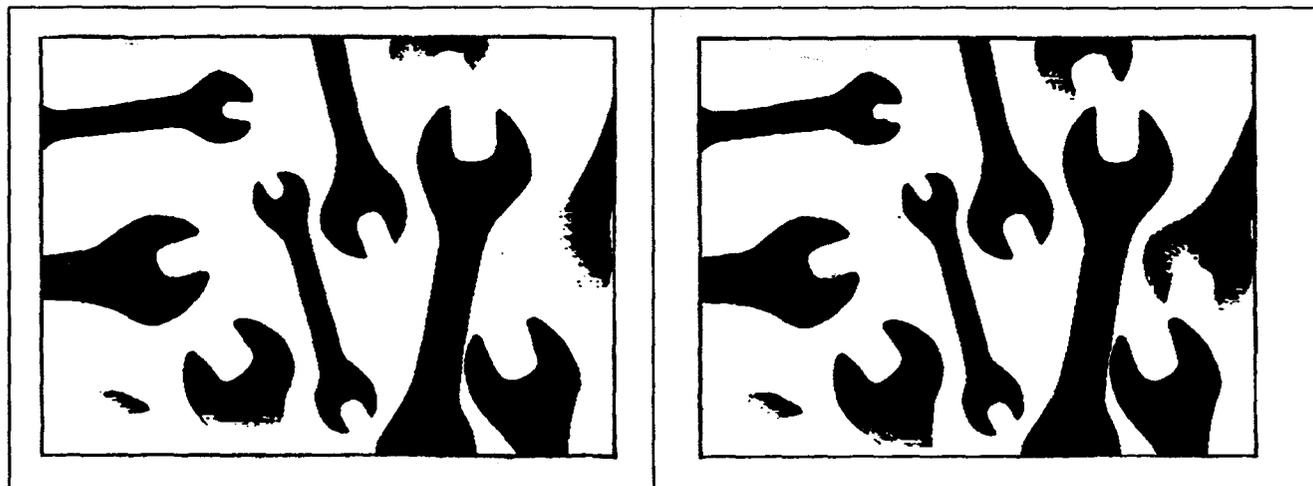
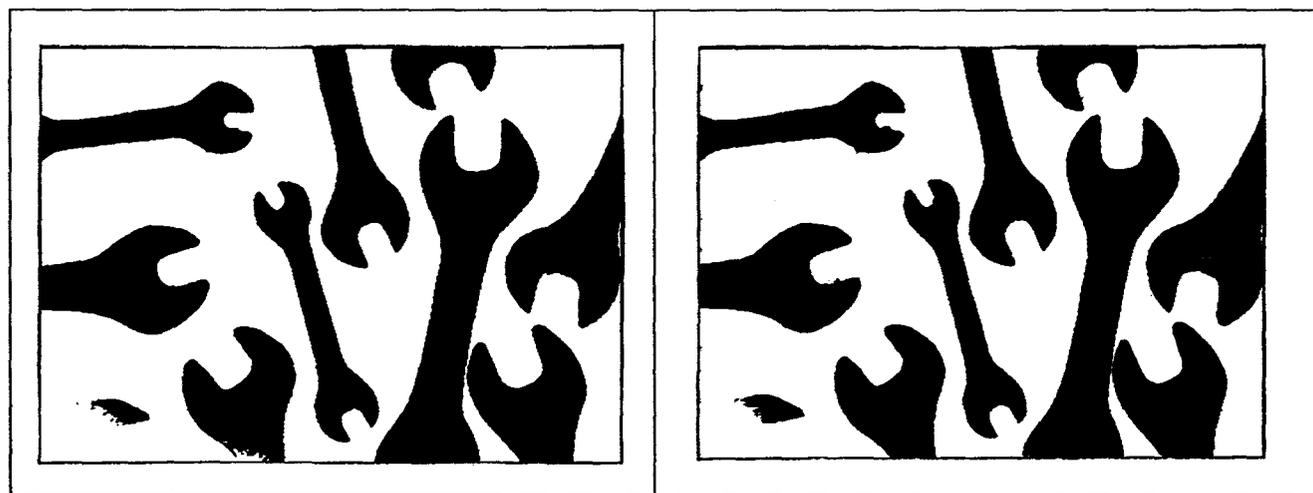


Fig. I-20 : Images binarisées successives.



(B₃)

(B₄)



(B₅)

(B₆)

Fig. I-20 : Images binarisées successives.



(B₇)

Fig. I-20 : Images binarisées successives .

Au bout de la huitième itération, les coefficients polynomiaux de la composante éclairément permettent au modèle de refléter avec une bonne approximation l'allure réelle des variations lumineuses d'éclairage, comme en témoigne l'image binarisée finale B_j .

VIII CONCLUSION.

Bien que la binarisation simple par seuillage global reste l'approche la plus utilisée pour segmenter une image, la qualité de la segmentation reste fortement tributaire des conditions d'éclairage de la scène observée.

Une technique de seuillage local adaptée aux variations spatiales basses fréquences constitue la première alternative pour segmenter une image prise dans des conditions défavorables d'éclairage.

Le recours à une technique de prétraitement permettant de corriger les variations lumineuses provoquées par le système d'éclairage représente une seconde alternative

qui vise à rendre utilisable une technique de segmentation par seuillage global de l'image prétraitée.

Nous avons vu que la méthode de prétraitement qui consiste à modéliser les variations lumineuses non désirées de l'image et à les retrancher de l'image d'origine afin de la rendre apte au seuillage global, conduit à des résultats d'autant plus satisfaisants que la surface occupée par le fond est prépondérante sur celle occupée par les objets.

C'est pourquoi, après l'étude détaillée d'un principe simple de prétraitement et de sa mise en application sur une image prise dans de mauvaises conditions d'éclairage, nous avons proposé un schéma itératif permettant d'améliorer la modélisation des variations spatiales de l'éclairage de la scène observée.

En effet, l'itération du processus de modélisation permet d'obtenir de proche en proche un modèle de plus en plus représentatif des variations réelles de l'éclairage. Cette approche est d'autant plus intéressante que les objets occupent une surface importante dans l'image.

Il convient, après correction des variations des niveaux de gris de l'image, de différencier les points des objets de ceux du fond de l'image. Cette différenciation peut être faite par un simple seuillage global. Nous allons étudier, dans le prochain chapitre, la manière de choisir les valeurs des seuils mises en jeu dans la procédure de seuillage global pour obtenir une segmentation significative des images.

- ANNEXES -

ANNEXE I

MODELISATION DES VARIATIONS D'ILLUMINATION SPATIALES

BASSES FREQUENCES DE L'ECLAIRAGE.

Soit $E(x,y)$ le modèle polynomial de degré d des variations spatiales basses fréquences de l'illumination de la scène observée. Sous sa forme la plus générale, ce modèle s'écrit :

$$E(x,y) = a_{0,0} + \dots + a_{0,d} \cdot x^d + a_{1,0} \cdot y + \dots + a_{1,d-1} \cdot x^{d-1} \cdot y + \dots + a_{d,0} \cdot y^d.$$

et sous une forme compacte :

$$E(x,y) = \sum_{r=0}^d \sum_{s=0}^r a_{r-s,r} \cdot x^s \cdot y^{r-s}.$$

La modélisation des variations de la composante illumination de la scène observée se fait en minimisant l'erreur quadratique E entre le modèle $E(x,y)$ et la fonction luminance $L(x,y)$ de l'image sur l'ensemble des points du maillage défini au chapitre I, avec $-n \leq i \leq n$ et $-n \leq j \leq n$:

$$E = \sum_{i=-n}^n \sum_{j=-n}^n [E(i,j) - L(i,j)]^2.$$

La minimisation de l'erreur quadratique est faite en annulant les $(d+1) \cdot (d+2)/2$ dérivées partielles de cette erreur par rapport aux coefficients de $E(x,y)$. On aboutit au système suivant :

$$\frac{\partial E}{\partial a_{0,0}} = 0, \dots, \frac{\partial E}{\partial a_{0,d}} = 0, \frac{\partial E}{\partial a_{1,0}} = 0, \dots, \frac{\partial E}{\partial a_{1,d-1}} = 0, \dots, \frac{\partial E}{\partial a_{d,0}} = 0.$$

qui, sous forme développée, s'écrit :

$$a_{0,0} \cdot N^2 + \dots + a_{0,d} \cdot p^d \sum i^d + a_{1,0} \cdot p \sum j + \dots + a_{1,d-1} \cdot p^d \sum i^{d-1} \cdot j + \dots + a_{d,0} \cdot p^d \sum j^d = \sum L(i, j)$$

$$a_{0,0} \sum i + \dots + a_{0,d} \cdot p^d \sum i^{d+1} + a_{1,0} \cdot p \sum i \cdot j + \dots + a_{1,d-1} \cdot p^d \sum i^d \cdot j + \dots + a_{d,0} \cdot p^d \sum i \cdot j^d = \sum i \cdot L(i, j)$$

.....

$$a_{0,0} \sum j^d + \dots + a_{0,d} \cdot p^d \sum i^d \cdot j^d + a_{1,0} \cdot p \sum j^{d+1} + \dots + a_{1,d-1} \cdot p^d \sum i^{d-1} \cdot j^{d+1} + \dots + a_{d,0} \cdot p^d \sum j^{2d} = \sum j^d \cdot L(i, j)$$

où \sum représente la double somme $\sum_{i=-n}^n \sum_{j=-n}^n$

La résolution de ce système permet de calculer les paramètres de E(x,y) tels que l'erreur quadratique soit minimale au sens des moindres carrés. Les deux annexes suivantes (annexe II et III) donnent la résolution des systèmes d'équations pour le degré 2 et 3 respectivement, qui sont les degrés les plus couramment utilisés pour le modèle E(x,y) .

ANNEXE II

MODELISATION POLYNOMIALE DE DEGRE 2 DES VARIATIONS D'ILLUMINATION SPATIALES BASSES FREQUENCES DE L'ECLAIRAGE.

Le modèle polynomial de degré 2 des variations spatiales d'illumination de l'éclairage s'écrit comme suit :

$$E(x,y) = a_{0,0} + a_{0,1} \cdot x + a_{0,2} \cdot x^2 + a_{1,0} \cdot y + a_{1,1} \cdot x \cdot y + a_{2,0} \cdot y^2 .$$

Les coefficients de $E(x,y)$ sont estimés en minimisant l'erreur quadratique entre les valeurs de $E(x,y)$ et les niveaux de gris $L(x,y)$ sur l'ensemble des points (i,j) du maillage défini au chapitre I, avec $-n \leq i \leq n$ et $-n \leq j \leq n$.

La minimisation de

$$E = \sum_{(x,y) \in \text{maillage}} [E(x,y) - L(x,y)]^2$$

conduit au système linéaire de 6 équations suivant :

$$\begin{aligned} a_{0,0} \cdot N^2 + a_{0,1} \cdot p \sum i + a_{0,2} \cdot p^2 \sum i^2 + a_{1,0} \cdot p \sum j + a_{1,1} \cdot p^2 \sum i \cdot j + a_{2,0} \cdot p^2 \sum j^2 &= h_0 \\ a_{0,0} \sum i + a_{0,1} \cdot p \sum i^2 + a_{0,2} \cdot p^2 \sum i^3 + a_{1,0} \cdot p \sum i \cdot j + a_{1,1} \cdot p^2 \sum i^2 \cdot j + a_{2,0} \cdot p^2 \sum i \cdot j^2 &= h_1 \\ a_{0,0} \sum j + a_{0,1} \cdot p \sum i \cdot j + a_{0,2} \cdot p^2 \sum i^2 \cdot j + a_{1,0} \cdot p \sum j^2 + a_{1,1} \cdot p^2 \sum i \cdot j^2 + a_{2,0} \cdot p^2 \sum j^3 &= h_2 \\ a_{0,0} \sum i \cdot j + a_{0,1} \sum i^2 \cdot j + a_{0,2} \cdot p^2 \sum i^3 \cdot j + a_{1,0} \cdot p \sum i \cdot j^2 + a_{1,1} \cdot p^2 \sum i^2 \cdot j^2 + a_{2,0} \cdot p^2 \sum i \cdot j^3 &= h_3 \\ a_{0,0} \sum i^2 + a_{0,1} \cdot p \sum i^3 + a_{0,2} \cdot p^2 \sum i^4 + a_{1,0} \cdot p \sum i \cdot j + a_{1,1} \cdot p^2 \sum i^2 \cdot j + a_{2,0} \cdot p^2 \sum i^2 \cdot j^2 &= h_4 \\ a_{0,0} \sum j^2 + a_{0,1} \cdot p \sum i \cdot j^2 + a_{0,2} \cdot p^2 \sum i^2 \cdot j^2 + a_{1,0} \cdot p \sum j^3 + a_{1,1} \cdot p^2 \sum i \cdot j^3 + a_{2,0} \cdot p^2 \sum j^4 &= h_5 \end{aligned}$$

où \sum représente la double somme $\sum_{i=-n}^n \sum_{j=-n}^n$

$$h_0 = \sum L(i,j) \quad h_3 = \sum i.j.L(i,j)$$

et $h_1 = \sum i.L(i,j) \quad h_4 = \sum i^2.L(i,j)$

$$h_2 = \sum j.L(i,j) \quad h_5 = \sum j^2.L(i,j)$$

Les 6 paramètres du modèle sont obtenus en résolvant les 6 équations linéaires précédentes.

Puisque $\sum i^q.j^p = 0$ lorsqu'au moins l'un des exposants q et p est impair, le système d'équations, résolu à partir de la méthode de Gauss-Jordan, se simplifie comme suit :

$$N^2.a_{0,0} + p^2.N.S_2.a_{0,2} + p^2.N.S_2.a_{2,0} = h_0$$

$$N.S_2.a_{0,0} + p^2.N.S_4.a_{0,2} + p^2.S_2^2.a_{2,0} = h_4$$

$$a_{0,0}.N.S_2 + p^2.S_2^2.a_{0,2} + p^2.N.S_4.a_{2,0} = h_5$$

avec $S_2 = \sum_{p=-n}^n p^2$, $S_4 = \sum_{p=-n}^n p^4$ et

$$N.a_{0,1}.p.S_2 = h_1$$

$$N.a_{1,0}.p.S_2^2 = h_2$$

$$a_{1,1}.p^2.S_2^2 = h_3$$

ANNEXE III

MODELISATION POLYNOMIALE DE DEGRE 3 DES VARIATIONS D'ILLUMINATION SPATIALES BASSES FREQUENCES DE L'ECLAIRAGE.

Le modèle polynomiale de degré 3 des variations spatiales basses fréquences d'illumination de l'éclairage s'écrit :

$$E(x,y) = a_{0,0} + a_{0,1}.x + a_{0,2}.x^2 + a_{0,3}.x^3 + a_{1,0}.y + a_{1,1}.x.y + a_{1,2}.x^2.y + a_{2,0}.y^2 + a_{2,1}.x.y^2 + a_{3,0}.y^3$$

Les coefficients de $E(x,y)$ sont ajustés en minimisant les erreurs quadratiques entre les valeurs de $E(x,y)$ et les niveaux de gris $L(x,y)$ sur l'ensemble des points (i,j) du maillage avec $-n \leq i \leq n$ et $-n \leq j \leq n$.

Après simplification, la minimisation de

$$E = \sum_{i=-n}^n \sum_{j=-n}^n [E(i,j) - L(i,j)]^2$$

conduit à un ensemble de 10 équations suivantes :

$$[A]. \begin{bmatrix} a_{0,1} \\ a_{0,3} \\ a_{2,1} \end{bmatrix} = \begin{bmatrix} h_1 \\ h_6 \\ h_8 \end{bmatrix}, [B]. \begin{bmatrix} a_{0,0} \\ a_{0,2} \\ a_{2,0} \end{bmatrix} = \begin{bmatrix} h_0 \\ h_4 \\ h_5 \end{bmatrix}, [A]. \begin{bmatrix} a_{1,0} \\ a_{1,2} \\ a_{3,0} \end{bmatrix} = \begin{bmatrix} h_2 \\ h_7 \\ h_9 \end{bmatrix} \text{ et } a_{3,0}.p.N.S_2 = h_2$$

$$\text{avec } [A] = \begin{bmatrix} p.N.S_2 & p^3.S_2^2 & p^3.N.S_4 \\ p.S_2^2 & p^3.S_2.S_4 & p^3.S_2.S_4 \\ N.p.S_4 & p^2.S_2.S_4 & N.p^3.S_6 \end{bmatrix} \text{ et } [B] = \begin{bmatrix} N^2 & p^2.N.S_2 & p^2.N.S_2 \\ N.S_2 & p^2.N.S_4 & p^2.S_2^2 \\ N.S_2 & p^2.S_2^2 & p^2.N.S_4 \end{bmatrix}$$

et

$$h_6 = \sum i^3.L(i,j)$$

$$h_7 = \sum i^2.j.L(i,j)$$

$$h_8 = \sum i.j^2.L(i,j)$$

$$h_9 = \sum j^3.L(i,j)$$

$$S_6 = \sum_{p=-n}^n p^6.$$

ANNEXE IV

EVOLUTION DES COEFFICIENTS DU MODELE DES VARIATIONS D'ILLUMINATION DE LA SCENE OBSERVEE DE L'IMAGE ETUDIEE AU CHAPITRE I.

L'itération du procédé est arrêtée lorsque les coefficients du modèle vérifient, entre deux itérations successives k et $k+1$, la relation :

$$\left| \frac{a_{i,j}^{(k)} - a_{i,j}^{(k+1)}}{a_{i,j}^{(k+1)}} \right| \leq \varepsilon \text{ où } \varepsilon \text{ a été choisi égal à } 10^{-1}$$

Première itération :

$a_{0,0} = 144$	$a_{1,1} = -4,2369.10^{-4}$
$a_{0,1} = -1,643.10^{-2}$	$a_{1,2} = 5,6438.10^{-6}$
$a_{0,2} = 3,2158.10^{-5}$	$a_{2,0} = -1,561.10^{-4}$
$a_{0,3} = -5,2787.10^{-8}$	$a_{2,1} = -3,32489.10^{-6}$
$a_{1,0} = -1,93649.10^{-4}$	$a_{3,0} = -3,772.10^{-7}$

Deuxième itération :

$a_{0,0} = 174,29$	$a_{1,1} = -2,199.10^{-4}$
$a_{0,1} = 0,1578$	$a_{1,2} = 2,372.10^{-6}$
$a_{0,2} = -2,3922.10^{-4}$	$a_{2,0} = -3,402.10^{-4}$
$a_{0,3} = 1,3947.10^{-6}$	$a_{2,1} = -2,0708.10^{-6}$
$a_{1,0} = -9,245.10^{-2}$	$a_{3,0} = -9,9848.10^{-8}$

Troisième itération :

$$a_{0,0} = 187,199$$

$$a_{0,1} = 0,2368$$

$$a_{0,2} = -3,6839.10^{-4}$$

$$a_{0,3} = 1,2969.10^{-6}$$

$$a_{1,0} = -0,117$$

$$a_{1,1} = -9,68.10^{-5}$$

$$a_{1,2} = 7,81.10^{-7}$$

$$a_{2,0} = -5,2696.10^{-4}$$

$$a_{2,1} = -1,2597.10^{-6}$$

$$a_{3,0} = 9,057.10^{-8}$$

Quatrième itération:

$$a_{0,0} = 193,52$$

$$a_{0,1} = 0,271$$

$$a_{0,2} = -4,366.10^{-4}$$

$$a_{0,3} = 1,1798.10^{-6}$$

$$a_{1,0} = -0,121$$

$$a_{1,1} = -3,744.10^{-5}$$

$$a_{1,2} = 4,307.10^{-8}$$

$$a_{2,0} = -4,332.10^{-4}$$

$$a_{2,1} = -8,7485.10^{-7}$$

$$a_{3,0} = 2,4307.10^{-8}$$

Cinquième itération :

$$a_{0,0} = 195,8$$

$$a_{0,1} = 0,3028$$

$$a_{0,2} = -4,56269.10^{-4}$$

$$a_{0,3} = 1,028.10^{-6}$$

$$a_{1,0} = -0,121$$

$$a_{1,1} = -1,88.10^{-5}$$

$$a_{1,2} = -3,762.10^{-7}$$

$$a_{2,0} = -4,209.10^{-4}$$

$$a_{2,1} = -7,779.10^{-7}$$

$$a_{3,0} = 1,743.10^{-7}$$

Sixième itération :

$$a_{0,0} = 197,69$$

$$a_{0,1} = 0,323$$

$$a_{0,2} = -4,6966.10^{-4}$$

$$a_{0,3} = 9,5289.10^{-7}$$

$$a_{1,0} = -0,1154$$

$$a_{1,1} = 1,799.10^{-6}$$

$$a_{1,2} = -6,42248.10^{-7}$$

$$a_{2,0} = -4,149.10^{-4}$$

$$a_{2,1} = -6,4248.10^{-7}$$

$$a_{3,0} = 1,0147.10^{-7}$$

Septième itération :

$$a_{0,0} = 199,19$$

$$a_{0,1} = 0,3349$$

$$a_{0,2} = -4,738.10^{-4}$$

$$a_{0,3} = 9,5289.10^{-7}$$

$$a_{1,0} = 0,3349$$

$$a_{1,1} = 1,2.10^{-6}$$

$$a_{1,2} = -7,1231.10^{-7}$$

$$a_{2,0} = -4,4638.10^{-4}$$

$$a_{2,1} = -9,77.10^{-7}$$

$$a_{3,0} = -1,654.10^{-7}$$

Huitième itération :

$$a_{0,0} = 199,56$$

$$a_{0,1} = 0,342$$

$$a_{0,2} = -4,7697.10^{-4}$$

$$a_{0,3} = 9,178.10^{-8}$$

$$a_{1,0} = 0,342$$

$$a_{1,1} = 1,102.10^{-5}$$

$$a_{1,2} = -7,377.10^{-7}$$

$$a_{2,0} = -4,4294.10^{-4}$$

$$a_{2,1} = -9,417.10^{-7}$$

$$a_{3,0} = -7,8377.10^{-7}$$

**II - UTILISATION DES CONCEPTS DE
L'ANALYSE STATISTIQUE DES DONNEES
POUR LA SEGMENTATION DES IMAGES -**

UTILISATION DES CONCEPTS DE L'ANALYSE STATISTIQUE DES DONNEES POUR LA SEGMENTATION DES IMAGES.

I INTRODUCTION.

Bien que la technique simple de seuillage global soit d'utilisation courante pour la segmentation des images, le résultat de cette approche peut être entaché d'erreurs si l'éclairage de la scène n'est pas uniforme. Cette raison nous a amenés à soulever ce problème majeur auquel la technique de seuillage global se trouve fréquemment confrontée. Deux alternatives possibles ont été développées dans le chapitre précédent.

Si une préférence est accordée à la technique de prétraitement des images plutôt qu'à l'approche par seuillage adaptatif, il convient, dans ce cas, de déterminer, après correction des variations des niveaux de gris de l'image, les différents seuils de segmentation qui donneront le résultat attendu.

L'approche la plus courante pour définir les seuils appropriés consiste à analyser les fréquences d'apparition des niveaux de gris des points dans l'image. Cet ensemble de fréquences, représenté sous la forme d'un histogramme des niveaux de gris, apporte une information statistique globale sur le contenu de l'image. Son analyse facilite la détermination des seuils pour la segmentation de l'image analysée. Un soin tout particulier doit être accordé au choix des seuils reposant sur une telle analyse. En effet, la comparaison du niveau de gris de tout point de l'image avec les valeurs des seuils de segmentation trouvés doit permettre de différencier les points appartenant au fond de ceux appartenant aux différents objets présents dans l'image.

Nous verrons, au début de ce chapitre, qu'il est possible, moyennant certaines connaissances a priori sur l'histogramme des niveaux de gris des points-image, de choisir les seuils qui permettent de segmenter l'image en utilisant une procédure de classification optimale des points de l'image. Le qualificatif d'optimal se justifie en ce sens que les seuils sélectionnés permettent de classer les pixels en fonction de leur niveau de gris en minimisant le taux d'erreur. Le formalisme de cette procédure retenue

pour segmenter l'image va être introduit sur la base de concepts mathématiques issus du domaine de l'analyse statistique des données dont elle relève.

Cependant, les connaissances requises par cette procédure optimale de segmentation sont rarement disponibles sur les images dont on ne connaît peu, pour ne pas dire rien, de leurs natures. En effet, la procédure optimale de décision opère généralement dans un environnement supervisé, dans lequel on dispose de connaissances a priori importantes sur la nature des données à analyser. Dans le cas d'images totalement inconnues, c'est à dire analysées dans un contexte non-supervisé, il faut faire appel à des procédures statistiques différentes qui consistent à découvrir la structure des données, sans information a priori sur leurs propriétés. Différentes procédures statistiques, entrant dans ce contexte, sont présentées en fin de ce chapitre. Elles débouchent sur l'identification des classes entre lesquelles se répartissent les points-image, de telle sorte que ceux assignés à une même classe possèdent des caractéristiques plus semblables que ceux assignés à des classes différentes.

II SEGMENTATION DES IMAGES PAR CLASSIFICATION DES POINTS-IMAGES.

II-1 Principe général de la segmentation.

La figure II-1 schématise la procédure de segmentation d'une image I constituée de N points-image répartis en Q types R_q de régions homogènes.

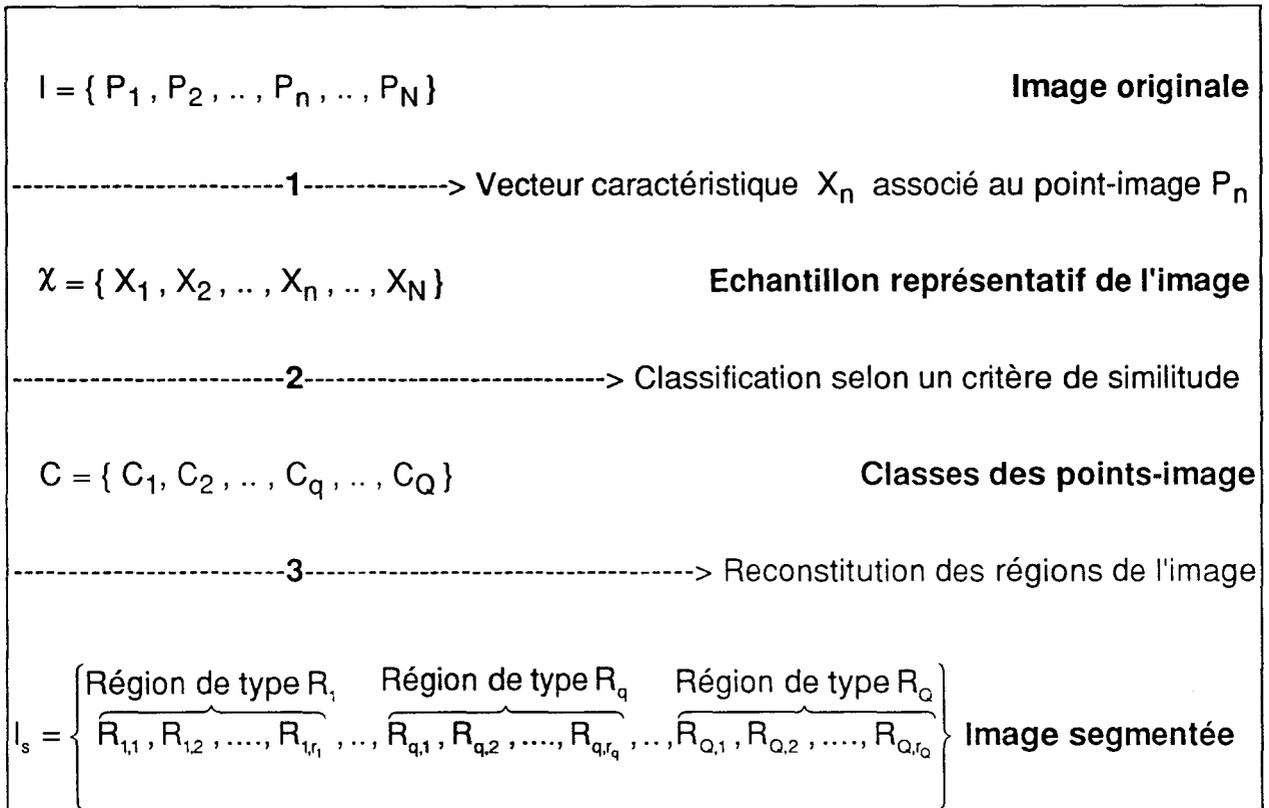


Fig. II-1 : Principe général de la segmentation des images en régions homogènes.

Cette figure illustre le cheminement classique suivi par beaucoup de procédures de segmentation. Ce principe général va maintenant être repris plus en détail afin de mieux définir les notions qui y sont introduites.

D'une manière générale, on suppose que l'image à analyser I est constituée de Q types de régions $R_1, R_2, \dots, R_q, \dots, R_Q$ qu'il s'agit d'identifier. Les régions homogènes de type R_q se composent de N_q points-image P_n parmi les N présents, de telle sorte que $N = N_1 + N_2 + \dots + N_q + \dots + N_Q$.

-1- La première phase de la procédure de segmentation, appelée phase de caractérisation des points-image, consiste à associer à chaque point-image P_n de l'image un vecteur X_n regroupant A attributs m_a , avec $a=1,2,\dots,A$, permettant de le caractériser.

Le vecteur attribut X_n associé au point-image P_n , appelé observation associée au point-image P_n , s'écrit sous la forme :

$$X_n = [m_1, m_2, \dots, m_a, \dots, m_A]^T.$$

Ce vecteur rassemble A valeurs numériques m_a , issues ou non d'un calcul, relevées sur le point-image P_n . Leurs natures, très diverses, peuvent être par exemple :

- la luminance, encore appelée niveau de gris, du point-image P_n ,
- une composante colorimétrique telle que le niveau d'une couleur primaire, la teinte ou la saturation du point,
- le module ou l'orientation du vecteur gradient en ce point-image,
- un attribut concernant la texture au voisinage immédiat du point-image P_n .

L'ensemble des observations associées à tous les points de l'image constitue un échantillon \mathcal{X} représentatif de l'image I . Cet échantillon se présente sous la forme de N observations multidimensionnelles :

$$\mathcal{X} = \{ X_1, X_2, \dots, X_n, \dots, X_N \}.$$

-2- A ce stade de l'analyse, identifier les régions homogènes de l'image consiste à analyser la structure globale de l'échantillon \mathcal{X} représentatif de l'image.

Les points-image auxquels sont associées des observations similaires, au sens d'un certain critère de similitude, se verront rassemblés dans la même classe. Ces

points sont alors dits de même type.

Notons que le critère de similitude utilisé, dans lequel intervient le jeu d'attributs des points-image, permet de formaliser mathématiquement le concept d'homogénéité au sein d'une région de l'image. Cette notion d'homogénéité peut être formulée de différentes manières. La plus courante définit une région homogène comme une région constituée de points-image de niveaux de gris similaires.

A la fin de la procédure de classification, les points-image se répartissent en Q classes distinctes $C_1, C_2, \dots, C_q, \dots, C_Q$. On note $C = \{ C_1, C_2, \dots, C_q, \dots, C_Q \}$ l'ensemble de ces Q classes.

Chaque point-image ressemble ainsi, au sens du critère de similitude, davantage aux points-image assignés à sa classe qu'à ceux classés différemment. Les points rassemblés dans une même classe C_q sont alors dits de type R_q .

-3- L'analyse de la connexité des points-image de même type R_q , au sens défini par exemple par Rosenfeld dans [Ros-70], permet de reconstruire les régions homogènes $R_{q,1}, R_{q,2}, \dots, R_{q,rq}$ du type correspondant.

De manière plus explicite, une région homogène de type R_q de l'image segmentée I_s est constituée par les points-image de la classe C_q qui sont connexes dans l'image I . La figure II-2, représentant une zone d'une image segmentée I_s , illustre le principe de reconstitution des régions homogènes selon une telle analyse.

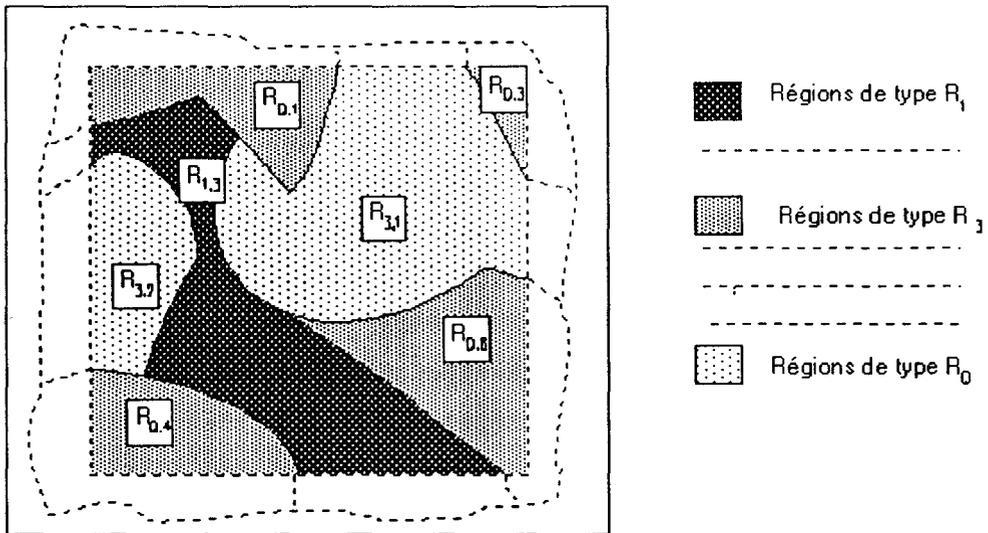


Fig. II-2 : Reconstitution des régions dans l'image segmentée I_s .

Sous une forme plus compacte, l'image segmentée peut s'écrire :

$$I_s = \left\{ \begin{array}{l} \text{Région de type } R_1 \quad \text{Région de type } R_q \quad \text{Région de type } R_0 \\ \overbrace{R_{1,1}, R_{1,2}, \dots, R_{1,r_1}} \quad \dots \quad \overbrace{R_{q,1}, R_{q,2}, \dots, R_{q,r_q}} \quad \dots \quad \overbrace{R_{0,1}, R_{0,2}, \dots, R_{0,r_0}} \end{array} \right\}$$

II-2 Simplification de la procédure de segmentation.

II-2-1 Caractérisation monodimensionnelle des points-image.

Plusieurs attributs, mesurés ou calculés sur chaque point-image, peuvent contribuer à une bonne caractérisation de chacun d'eux et, par conséquent, faciliter leur discrimination. Cependant, un seul attribut peut parfois suffire pour mener à bien la segmentation de l'image étudiée.

Pour des images monochromatiques, le choix de l'attribut se porte généralement, pour des raisons de commodité, sur le niveau de gris. En effet, l'obtention de la valeur de tout autre attribut sur les points-image nécessite généralement un calcul après l'acquisition de l'image.

Pour délimiter la plage continue des niveaux de gris des points de chaque type de régions homogènes, $Q-1$ seuils $T_1, T_2, \dots, T_q, \dots, T_{Q-1}$ sont à définir. L'identification des points-image de type R_q repose ensuite sur une simple comparaison des niveaux de gris des points de l'image avec les valeurs des seuils T_{q-1} et T_q correspondants. Les points retenus pour constituer une région sont ceux dont les niveaux de gris se situent entre ces deux seuils.

II-2-2 Binarisation de l'image.

La binarisation est une procédure simplifiée du seuillage en régions multiples. Cette procédure ne nécessite qu'un seuil unique T afin de décomposer l'image en deux types de régions homogènes. Les points de l'image dont les niveaux de gris sont inférieurs à ce seuil T constituent le premier type R_1 de régions. Les autres points-image représentent, quant à eux, le second type R_2 de régions de l'image.

Si le fond de l'image est plus sombre que les objets, les points du fond sont du premier type tandis que les points des objets du second. Si à l'opposé les objets sont disposés sur un fond clair, les points des objets constituent le premier type de régions tandis que les points du fond le second.

Pour des raisons de simplification, l'hypothèse selon laquelle l'image se compose uniquement de deux types de régions va être émise dans le paragraphe suivant.

III SEGMENTATION DES IMAGES VUE SOUS L'ANGLE DE L'ANALYSE DE DONNEES.

En général, il est difficile de décider de l'appartenance des points-image à l'une des deux classes sans commettre d'erreur. Les points les plus sombres en niveau de gris de la classe claire C_2 peuvent être plus sombres que les points les plus clairs de la classe sombre C_1 . Si les erreurs sont inévitables, on peut tout au moins tenter de les minimiser. On peut faire appel, pour cela, aux règles de décision optimales issues des travaux sur la classification statistique des données [Dud-73, Alb-64]. Le formalisme de cette règle va maintenant être défini sur la base de concepts

mathématiques relevant du domaine de l'analyse statistique.

III-1 Analyse statistique de l'image.

L'échantillon \mathcal{X} , représentatif de l'image I , regroupe l'ensemble des niveaux de gris des points-image. Il peut être considéré statistiquement comme une distribution $p(g(P_n))$ de la variable niveau de gris de l'image. Chaque niveau de gris $g(P_n)$ d'un point P_n de l'image, constitue une réalisation particulière de la variable aléatoire niveau de gris.

Dans le cadre d'une analyse statistique, on peut supposer que la distribution $p(g(P_n))$ associée à l'image admette un modèle probabiliste de la forme :

$$p(g(P_n)) = \sum_{q=1}^2 P_q \cdot p(g(P_n) | q)$$

où $p(g(P_n) | q)$ est la fonction de densité de probabilité conditionnelle qui définit la distribution des niveaux de gris des points de la classe C_q . La probabilité a priori de la classe C_q , notée P_q , représente la probabilité pour qu'un point-image tiré au hasard dans l'image appartienne à cette classe C_q . Cette probabilité n'est autre que le rapport entre la surface occupée par les points-image de type R_q et la surface de l'image entière. Cette probabilité s'écrit sous la forme :

$$P_q = \frac{N_q}{N}$$

où N_q est le nombre de points de type R_q parmi les N constituant l'image.

III-2 Règle de décision optimale.

La règle de décision optimale permet d'assigner un point-image P_n à l'une des deux classes présentes avec un minimum d'erreur. Le risque associé à la prise de décision est également évalué. La prise de décision qui permet d'assigner un point à l'une ou l'autre des deux classes C_1 ou C_2 s'appuie sur une évaluation des probabilités a posteriori pour que le point P_n appartienne à chacune des deux classes.

Ces probabilités a posteriori, notées $P(q | g(P_n))$, se calculent à partir de la règle de Bayes :

$$P(q | g(P_n)) = \frac{P_q \cdot p(g(P_n) | q)}{p(g(P_n))} \quad \text{avec } q = 1, 2.$$

Afin que le risque d'erreur de classement de P_n soit minimal, l'approche la plus naturelle consiste à assigner ce point à la classe pour laquelle sa probabilité d'appartenance est la plus élevée.

La règle de décision s'écrit donc :

si $P(1 | g(P_n)) \geq P(2 | g(P_n))$ alors $P_n \in C_1$

si $P(1 | g(P_n)) < P(2 | g(P_n))$ alors $P_n \in C_2$.

En exprimant les probabilités a posteriori à l'aide de la règle de Bayes et en remarquant que $p(g(P_n))$ ne dépend pas de la classe considérée, l'écriture de la règle se simplifie sous la forme :

si $P_1 \cdot p(g(P_n) | 1) \geq P_2 \cdot p(g(P_n) | 2)$ alors $P_n \in C_1$

si $P_1 \cdot p(g(P_n) | 1) < P_2 \cdot p(g(P_n) | 2)$ alors $P_n \in C_2$.

L'erreur ϵ_q associée à cette stratégie de décision est donnée par :

si $P_n \in C_1$ alors $\epsilon_1 = P_2 \cdot p(g(P_n) | 2)$

si $P_n \in C_2$ alors $\epsilon_2 = P_1 \cdot p(g(P_n) | 1)$.

Ce n'est que lorsque tous les points de l'image ont été classés soit dans C_1 , soit dans C_2 par la procédure de décision, que les points des deux types de régions R_1 et R_2 sont identifiés dans l'image.

III-3 Hypothèse normale émise sur la répartition statistique des niveaux de gris.

La règle de la décision optimale va maintenant être présentée sous l'hypothèse selon laquelle la répartition statistique des niveaux de gris des points-image de chacun des deux types de régions R_1 et R_2 de l'image suit une loi de distribution normale. On peut envisager l'utilisation de la règle de décision optimale en émettant aucune hypothèse sur la forme analytique des distributions des niveaux de gris au sein de chaque classe. On débouche alors sur des procédures non paramétriques [Has-66, Day-69]. Une autre solution consiste à supposer qu'il existe un modèle analytique des distributions. Sous cette hypothèse dite "paramétrique", on utilise généralement les lois normales qui sont certainement les plus répandues dans la pratique [Sok-63, Bal-65].

La distribution normale statistique des niveaux de gris des points-image de la région R_q , apparaissant dans la distribution statistique de l'image entière proportionnellement à la probabilité a priori P_q , se présente alors sous la forme :

$$p(g(P_n) | q) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma_q}} \cdot \exp \left[-\frac{(g(P_n) - \mu_q)^2}{2 \cdot \sigma_q} \right]$$

où μ_q et σ_q sont respectivement la moyenne et la variance des niveaux de gris des points de la région R_q . Ces paramètres sont définis par les relations suivantes :

$$\mu_q = \frac{1}{N_q} \sum_{P_n \in C_q} g(P_n)$$

$$\sigma_q = \frac{1}{N_q} \sum_{P_n \in C_q} (g(P_n) - \mu_q)^2.$$

En général, le nombre de points d'une image est suffisamment élevé pour que le mélange $p(g(P_n))$ des deux distributions statistiques puisse être estimé par l'histogramme $h(g(P_n))$ des niveaux de gris des points de l'image.

Sous l'hypothèse normale, la règle de la décision optimale consiste à binariser l'image à un seuil T_{opt} dont le niveau de gris correspond à celui du point d'intersection des deux fonctions de probabilité qui constituent le mélange représentant la distribution des niveaux de gris sur toute l'image (figure II-3)

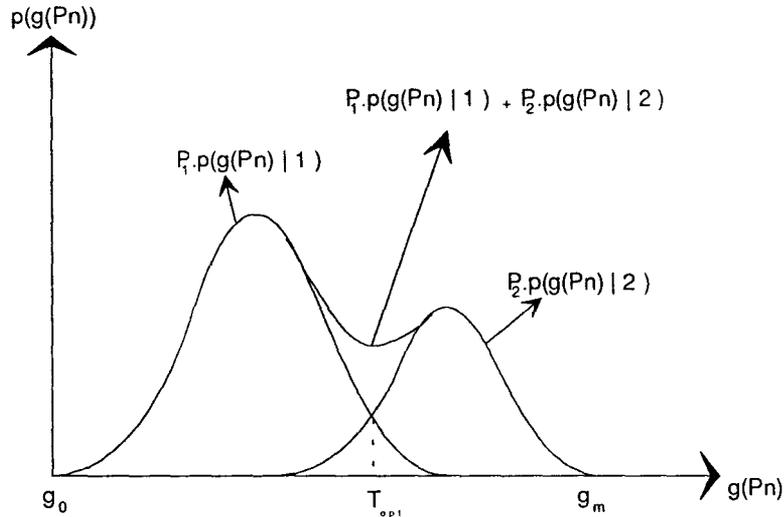


Fig. II-3 : Distribution statistique $p(g(P_n))$ des niveaux de gris de l'image.

Ce seuil T_{opt} vérifie la relation :

$$P_1 \cdot p(T_{opt} | 1) = P_2 \cdot p(T_{opt} | 2).$$

Ainsi, pour un point-image P_n de niveau de gris $g(P_n)$,

si $g(P_n) \leq T_{opt}$ alors $P_1 \cdot p(g(P_n) | 1) \geq P_2 \cdot p(g(P_n) | 2)$, P_n est assigné à la classe C_1

si $g(P_n) > T_{opt}$ alors $P_1 \cdot p(g(P_n) | 1) < P_2 \cdot p(g(P_n) | 2)$, P_n est assigné à la classe C_2 .

La résolution de l'équation $P_1 \cdot p(T_{opt} | 1) = P_2 \cdot p(T_{opt} | 2)$ conduit au seuil optimal suivant [Mar-88]:

$$T_{opt} = \frac{\mu_1 \cdot \sigma_2 - \mu_2 \cdot \sigma_1}{\sigma_2 - \sigma_1} \pm \frac{\sigma_2 \cdot \sigma_1}{\sigma_2 - \sigma_1} \cdot \left[(\mu_1 - \mu_2)^2 + 2 \cdot (\sigma_2 - \sigma_1) \cdot \ln \left(\frac{\sqrt{\sigma_1} \cdot P_2}{\sqrt{\sigma_2} \cdot P_1} \right) \right]^{\frac{1}{2}}.$$

La procédure de seuillage global de l'image originale I par ce seuil optimal T_{opt}

conduit à une image segmentée I_s constituée de points $b(x,y)$ dont les niveaux sont tels que :

$$b(x,y) = \begin{cases} 0 & \text{si } g(P_n(x,y)) \leq T_{opt} \\ 1 & \text{si } g(P_n(x,y)) > T_{opt} \end{cases}$$

La théorie de la décision indique comment implanter une procédure de classification optimale des points-image à partir de la connaissance des fonctions de densité de probabilité associées aux classes des points en présence. Dans la pratique, on ne dispose, en général, d'aucune information a priori sur les fonctions de densité de probabilité mises en jeu dans la procédure de décision. Les paramètres statistiques de ces fonctions sont alors généralement estimés directement à partir de l'histogramme des niveaux de gris des points de l'image.

III-4 Estimation des fonctions normales de densité de probabilité.

Dans le cas d'un problème de classification des points-image en deux classes, un seuil arbitraire T peut être utilisé pour définir les deux classes de points-image. Les points de la première classe sont ceux dont les niveaux de gris sont inférieurs au seuil T qui scinde l'histogramme en deux. La seconde classe est formée des points dont les niveaux de gris lui sont supérieurs. La fonction de densité de probabilité des niveaux de gris, au sein de chaque classe, est ensuite modélisée sous la forme d'une composante normale :

$$p(g(P_n) | q) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma_q(T)}} \cdot \exp \left[-\frac{(g(P_n) - \mu_q(T))^2}{2 \cdot \sigma_q(T)} \right]$$

dont les paramètres statistiques, c'est à dire la moyenne des niveaux de gris $\mu_q(T)$ et la variance des niveaux de gris $\sigma_q(T)$, sont calculés à partir de l'histogramme $h(g(P_n))$ comme suit :

$$\mu_q(T) = \frac{1}{P_q(T)} \sum_{g(P_n)=a}^b g(P_n) \cdot h(g(P_n))$$

$$\sigma_q(T) = \frac{1}{P_q(T)} \sum_{g(P_n)=a}^b (g(P_n) - \mu_q(T))^2 \cdot h(g(P_n))$$

$$\text{avec } a = \begin{cases} g_0 & \text{si } q = 1 \\ T+1 & \text{si } q = 2 \end{cases} \quad \text{et} \quad b = \begin{cases} T & \text{si } q = 1 \\ g_m & \text{si } q = 2 \end{cases}$$

où g_0 et g_m sont les niveaux de gris minimal et maximal de l'image.

Chaque fonction $p(g(P_n) | q)$ est ensuite pondérée par la probabilité a priori $P_q(T)$ qui lui est associée afin qu'elle puisse représenter la contribution statistique des niveaux de gris des points d'une classe parmi les autres classes présentes. Cette probabilité est estimée à partir de l'histogramme des niveaux de gris sous la forme :

$$P_q(T) = \sum_{g(P_n)=a}^b h(g(P_n)).$$

Il s'agit ensuite de définir une stratégie pour déterminer un seuil T^* le plus proche possible de l'optimal théorique T_{opt} . Pour atteindre ce but, deux principales approches se dégagent de la littérature. La première consiste à définir un critère pour évaluer le degré de ressemblance entre l'histogramme des niveaux de gris de l'image étudiée et la modélisation normale des fonctions de densité de probabilité associées aux deux classes de points constituées [Kit-85, Ye-88]. La seconde approche, basée sur l'équation théorique vérifiée par le seuil optimal, procède par recherche itérative du seuil de binarisation [Kit-86, Rid-78, Tru-79]. Ces deux principales approches vont maintenant être présentées et comparées.

III-5 Approches statistiques de classification.

- De nombreuses solutions sont proposées dans la littérature dans le cadre de la première approche. Retenons l'une des plus connues, celle de Kittler et Illingworth [Kit-85, Ye-88] qui définissent un critère $C(T)$ évaluant le degré de corrélation entre chaque modèle estimé $P_q(T).p(g | q, T)$ de la contribution de chaque classe C_q à la fonction de densité de probabilité associée à la distribution réelle $h(g(P_n))$ des niveaux de gris de l'histogramme :

$$C(T) = \sum_{g(P_n)=g_0}^{g_m} h(g(P_n)).[P_1(T).p(g(P_n) | 1, T) + P_2(T).p(g(P_n) | 2, T)].$$

Le maximum de ce critère correspond au seuil T^* qui décompose l'histogramme en deux distributions les plus proches d'une forme normale au sens du critère $C(T)$. Ce seuil T^* est celui retenu pour binariser l'image.

Pour des raisons algorithmiques, les auteurs proposent un second critère $J(T)$ sous la forme :

$$J(T) = \sum_{g(P_n)=g_0}^T [-2.\ln(P_1(T).p(g | 1, T))] + \sum_{g(P_n)=T+1}^{g_m} [-2.\ln(P_2(T).p(g | 2, T))].$$

qui, après simplification, se réduit à l'expression :

$$J(T) = 1 + 2[P_1(T).\ln\sigma_1(T) + P_2(T).\ln\sigma_2(T)] - 2[P_1(T).\ln P_1(T) + P_2(T).\ln P_2(T)].$$

Certaines propriétés de cette approche statistique méritent d'être citées.

En général le seuil trouvé T^* diffère peu du seuil optimal T_{opt} fourni par la théorie de la décision. Néanmoins, il n'est pas à écarter qu'une différence non négligeable entre le seuil trouvé et celui recherché, induite par la scission de l'histogramme en deux classes de points, puisse altérer la qualité des résultats. Cet écart peut toutefois être réduit moyennant certains calculs supplémentaires [Cho-89].

Contrairement à certaines approches de segmentation telles que l'approche

proposée par Vogel et Wong en [Vog-79], aucun lissage préalable de l'histogramme analysé n'est nécessaire. Par ailleurs, cette approche ne fait appel à aucune connaissance a priori sur les fonctions de densité de probabilité des niveaux de gris associées aux deux classes de points de l'image. Or, bien souvent, certains paramètres statistiques dont dépendent ces fonctions doivent être connus a priori. C'est le cas, par exemple, de l'approche de Cazes [Caz-76] qui nécessite, pour son bon fonctionnement, la connaissance de la moyenne des niveaux de gris de chaque composante de l'histogramme.

- Pour la seconde approche, Kittler et Illingworth [Kit-86] proposent une méthode de recherche itérative du seuil de binarisation basée sur la relation vérifiée par les deux distributions normales au seuil optimal T_{opt} , à savoir :

$$P_1 \cdot p(T_{opt} | 1) = P_2 \cdot p(T_{opt} | 2).$$

Après simplification, cette relation se ramène à l'expression suivante :

$$\left[\frac{T_{opt} - \mu_1}{\sigma_1} \right]^2 + 2 \cdot \ln \sigma_1 - 2 \cdot \ln P_1 = \left[\frac{T_{opt} - \mu_2}{\sigma_2} \right]^2 + 2 \cdot \ln \sigma_2 - 2 \cdot \ln P_2.$$

À l'étape initiale, la moyenne des niveaux de gris de l'histogramme $h(g(P_n))$ est utilisée comme premier seuil T_0 . Ce seuil T_0 scinde l'histogramme en deux classes de points sur lesquelles sont estimés les paramètres $P_q(T_0)$, $\mu_q(T_0)$ et $\sigma_q(T_0)$, pour $q=1$ et $q=2$. Les valeurs estimées de ces paramètres sont ensuite remplacées dans l'équation précédente afin de définir le seuil T_1 de l'étape suivante :

$$\left[\frac{T_1 - \mu_1(T_0)}{\sigma_1(T_0)} \right]^2 + 2 \cdot \ln \sigma_1(T_0) - 2 \cdot \ln P_1(T_0) = \left[\frac{T_1 - \mu_2(T_0)}{\sigma_2(T_0)} \right]^2 + 2 \cdot \ln \sigma_2(T_0) - 2 \cdot \ln P_2(T_0).$$

Ce nouveau seuil T_1 scinde l'histogramme en deux nouvelles classes de points. Ces deux dernières sont à leur tour modélisées sous la forme de fonctions de distributions normales. Le niveau de gris de leur point d'intersection définit le seuil T_2

de l'itération suivante. La procédure est itérée jusqu'à stabilisation du seuil de binarisation.

L'utilisation de cet algorithme se révèle peu concluante car la valeur du seuil peut converger vers le niveau de gris minimal g_0 ou maximal g_m de l'image.

De plus, lorsque les deux régions de l'image sont constituées d'un nombre très inégal de points, le seuil a tendance à converger vers la moyenne des niveaux de gris de la classe prépondérante, c'est à dire celle associée à la région de l'image de surface la plus grande. Ceci est dû au choix du seuil initial T_0 , pris égal à la moyenne des niveaux de gris de l'histogramme, dont la valeur se trouve proche de celle de la moyenne de la classe de points prédominante. L'évolution du seuil au cours des itérations n'est alors pas marquante car celui-ci se stabilise à un niveau très proche de cette moyenne.

Cet algorithme de recherche itérative du seuil présente l'inconvénient majeur d'être fortement sensible au choix du seuil initial T_0 . Afin de remédier à ce problème, Ridler [Rid-78] et Trussel [Tru-79] recommandent une méthode particulière, connue sous le nom d'approche "Isodata", pour rechercher de manière itérative le seuil de binarisation de l'image.

Le principe de cette méthode repose sur l'hypothèse que la différence entre les moyennes en niveaux de gris μ_1 et μ_2 des deux classes de points-image est suffisamment élevée pour que les deux variances en niveau de gris σ_1 et σ_2 puissent être négligées dans l'expression mathématique du seuil optimal. L'écriture de ce seuil T_{opt} se trouve ainsi réduite à sa plus simple expression :

$$T_{opt} = \frac{\mu_1 + \mu_2}{2}.$$

Sous cette hypothèse simplificatrice, les auteurs proposent de diviser l'histogramme des niveaux de gris par un seuil initial T_0 choisi à la moyenne des niveaux de gris des points de l'image puis de calculer les moyennes en niveau de gris $\mu_1(T_0)$ et $\mu_2(T_0)$ de chaque population résultante.

L'étape suivante de l'algorithme itératif consiste à placer le seuil de binarisation au milieu de ces deux moyennes. Ce seuil T_1 est alors plus proche du milieu des

moyennes estimées des deux populations de points, donc plus proche de la valeur simplifiée T_{opt} du seuil optimal. L'itération de ce procédé se poursuit jusqu'à stabilisation du seuil.

Bien que la convergence de cet algorithme itératif ait été montrée expérimentalement sur plusieurs images, la garantie d'obtenir un seuil satisfaisant n'est pas toujours assurée. Elle dépend principalement de l'importance relative de chacune des deux classes de points présentes dans l'image. Ce problème a fait l'objet du travail récent de Lloyd [Llo-85] qui modifie l'algorithme Isodata en prenant en compte la probabilité a priori de chacune des deux distributions pour déterminer la valeur du seuil à chaque itération.

En conclusion, deux contraintes limitent les performances de cette seconde approche:

- Les résultats sont fortement tributaires de la valeur choisie pour le seuil initial.
- Les deux classes de points doivent être sensiblement équiprobables pour éviter tout déplacement du seuil vers la classe la plus importante.

IV CONCLUSION.

Bien qu'il soit possible de parvenir à une classification des points-image en prenant un minimum de risques d'erreurs, la loi qui régit cette prise de décision optimale ne peut s'appliquer que dans un contexte supervisé. L'utilisation de la loi optimale de classification n'est, en effet, envisageable que si les distributions statistiques des niveaux de gris des points de chaque classe présente dans l'image sont connues. Si cette condition n'est pas vérifiée, le risque d'erreurs associé à toute autre tentative de classification des points-image sera inévitablement plus élevé. Dans un tel contexte non supervisé, il est courant d'émettre l'hypothèse de normalité de la distribution des niveaux de gris de chaque classe de points. Mais, même si l'hypothèse de normalité est vérifiée, le risque d'une mauvaise classification des points-image se trouve, dans bien des cas, très élevé si les distributions du mélange analysé sont bruitées et se recouvrent partiellement. Il nous paraît donc intéressant d'atteindre une classification aussi proche que possible de la classification optimale même si le mélange analysé est constitué de distributions qui se chevauchent où s'écartent du profil normal attendu. C'est dans cette perspective que notre étude se poursuit et nous amène à proposer, dans le chapitre suivant, une nouvelle approche statistique de classification des points-image pour la segmentation des images.

**III - UNE NOUVELLE APPROCHE D'ANALYSE
STATISTIQUE POUR LA
SEGMENTATION DES IMAGES -**

UNE NOUVELLE APPROCHE D'ANALYSE STATISTIQUE

POUR LA SEGMENTATION DES IMAGES.

I INTRODUCTION.

Les erreurs d'identification des distributions commises sont dues essentiellement au fait que les approches de classification se contentent généralement d'émettre l'hypothèse de normalité sans toutefois l'exploiter véritablement. Leurs méthodologies se basent uniquement sur cette hypothèse pour considérer le problème d'identification des distributions comme un problème simple d'estimation des paramètres statistiques dont dépendent ces distributions.

Mais l'hypothèse d'un écart entre la distribution réelle de chaque classe de points à identifier et sa distribution normale idéale est rarement prise en compte dans la procédure de classification. Pour ne pas écarter cette éventualité, la démarche que nous proposons consiste à retenir la classification des points qui, au sens d'un critère simple, maximise la ressemblance entre la distribution réelle de chaque classe constituée et la distribution normale qui lui est associée. Notre approche possède l'avantage de fournir une classification significative si les distributions associées aux classes à identifier n'apparaissent pas de manière évidente dans l'espace des attributs du fait de leurs chevauchements importants.

II NOUVELLE APPROCHE D'ANALYSE STATISTIQUE DES POINTS-IMAGE POUR LA SEGMENTATION DES IMAGES.

II-1 Classification monodimensionnelle des points-image en deux classes.

II-1-1 Principe de l'approche.

Pour identifier les deux types de régions présents dans l'image, à savoir le premier constitué des points-image des objets et le second des points du fond de l'image, nous proposons une analyse statistique de l'histogramme des niveaux de gris des points de l'image. Pour cela, nous émettons l'hypothèse courante selon laquelle les niveaux de gris des points de l'image sont distribués suivant une loi normale caractéristique du type de régions auxquels ils appartiennent.

Il s'agit donc, pour segmenter une image formée de deux types de régions, d'identifier les deux composantes normales qui composent l'histogramme analysé (fig. III-1). Pour arriver à cet objectif, notre stratégie consiste à décomposer l'histogramme en deux composantes telles que leurs distributions associées soient, au sens d'un critère que nous allons définir, le plus proche possible d'une forme normale.

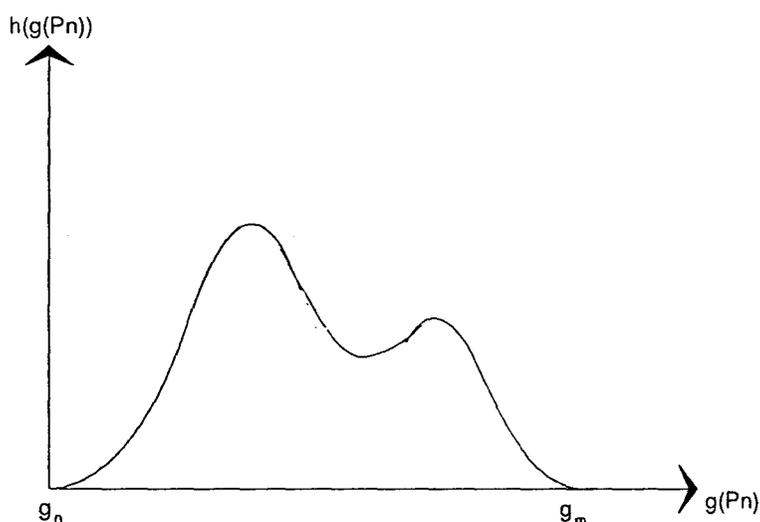


Fig. III-1 : Histogramme correspondant à une image formée de deux régions.

Pour cela, soit T un niveau de gris arbitraire pris comme seuil de binarisation. Ce seuil divise l'histogramme en deux classes de points. La première, notée C_1 , est

constituée des points-image dont les niveaux de gris sont inférieurs à T . La seconde regroupe les points-image dont les niveaux de gris sont supérieurs à ce seuil (fig. III-2).

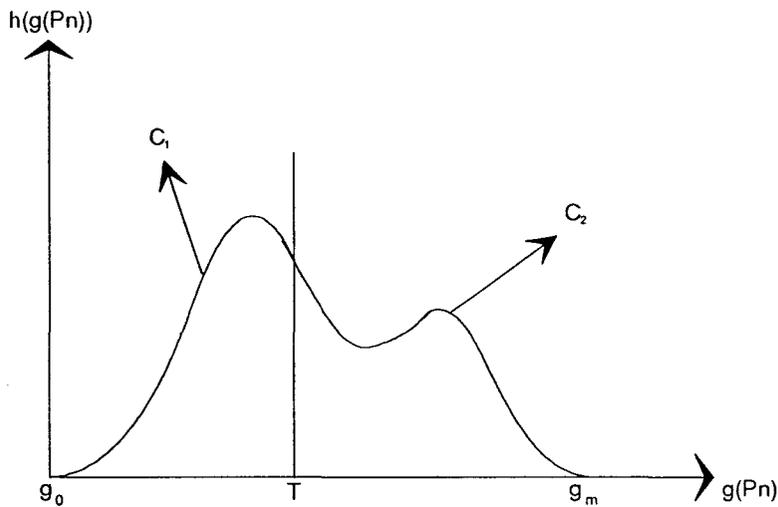


Fig. III-2 : Décomposition de l'histogramme en deux classes.

Comme l'illustre la figure III-3, chacune des deux fonctions de densité de probabilité des niveaux de gris des points associées aux classes C_q résultantes, pour $q=1,2$, est ensuite modélisée par une distribution normale de la forme :

$$p(g(P_n) | q) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma_q}} \cdot \exp \left[-\frac{(g(P_n) - \mu_q)^2}{2 \cdot \sigma_q} \right]$$

où μ_q et σ_q sont respectivement la moyenne et la variance des niveaux de gris des points de la classe C_q . Ces paramètres sont définis par les relations suivantes :

$$\mu_q = \frac{1}{N_q} \sum_{P_n \in C_q} g(P_n)$$

$$\sigma_q = \frac{1}{N_q} \sum_{P_n \in C_q} (g(P_n) - \mu_q)^2$$

avec $P_n \in C_1$ si $g(P_n) \in [g_0, T]$

avec $P_n \in C_2$ si $g(P_n) \in [T+1, g_m]$

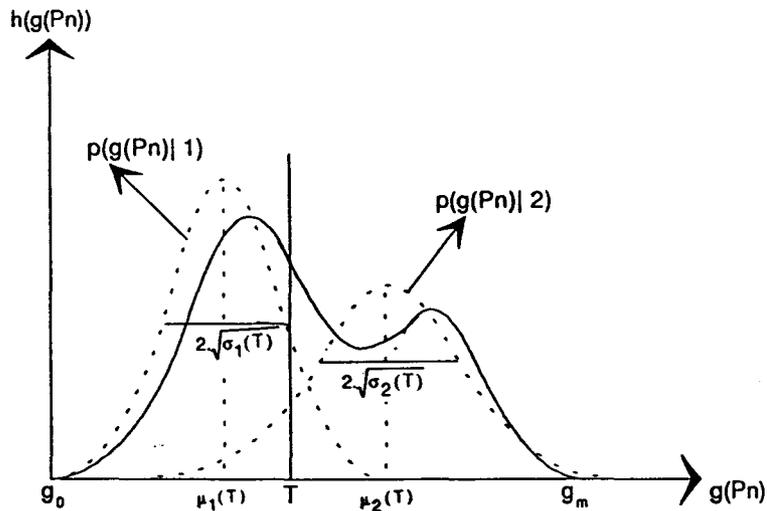


Fig. III-3 : Modélisation normale de l'histogramme.

Pour le niveau de gris particulier T pris comme seuil de binarisation, un critère $J(T)$, évaluant la qualité de la décomposition de l'histogramme en deux composantes normales, est calculé sous la forme :

$$J(T) = \sum_{g=g_0}^T \left[\frac{h(g(P_n))}{P_1(T)} - p(g(P_n) | 1, T) \right]^2 + \sum_{g=T+1}^{g_m} \left[\frac{h(g(P_n))}{P_2(T)} - p(g(P_n) | 2, T) \right]^2$$

où $P_q(T)$, $q=1,2$, qui représente l'importance relative de chaque classe C_q dans le mélange, est définie par :

$$P_q(T) = \frac{1}{N} \sum_{P_n \in C_q} h(g(P_n)).$$

Ce critère représente l'erreur quadratique entre le modèle normal du mélange des deux classes et l'histogramme réel des niveaux de gris. Cette différence est calculée entre la fonction de densité de probabilité $h(g(P_n))/P_q(T)$ de chaque classe et son modèle normal $p(g(P_n) | q, T)$ afin que le résultat ne soit pas influencé par le nombre de points des deux types de classes.

Ce critère de segmentation $J(T)$ est évalué pour chacun des niveaux de gris candidat au seuil de binarisation de l'image. Le seuil optimal T^* est ensuite choisi au niveau de gris pour lequel le critère $J(T)$ est minimal. Ce niveau de gris T^* retenu correspond à la décomposition de l'histogramme en 2 composantes les plus proches du modèle normal au sens du critère $J(T)$.

II-1-2 Résultats expérimentaux.

L'image servant d'illustration à notre algorithme de segmentation est constituée de deux régions (fig. III-4). Chaque région est formée de points dont les niveaux de gris résultent de l'addition d'un bruit uniforme à une constante. Les caractéristiques statistiques de ces deux régions sont les suivantes :

	première région	deuxième région
probabilité a priori	$P_1=0,75$	$P_2=0,25$
moyenne en niveau de gris	$\mu_1=65$	$\mu_2=127$
variance en niveau de gris	$\sigma_1=24$	$\sigma_2=21$

L'histogramme de cette image se compose de deux distributions normales bruitées présentant un chevauchement relativement important (fig. III-5).

L'évaluation du critère de binarisation $J(T)$ pour tous les niveaux de gris disponibles de l'image fait apparaître un minimum au niveau de gris 100 (fig. III-6).

C'est avec ce seuil que les deux parties de l'histogramme sont les plus proches de composantes normales au sens du critère défini (fig. III-7). L'image de la figure III-8 est donc binarisée avec ce seuil. Un filtre de type médian 3x3 a été appliqué sur l'image segmentée afin d'éliminer les points isolés assimilés à du bruit. On s'aperçoit, en comparant l'image segmentée à l'image originale, que les deux régions homogènes ont

comparant l'image segmentée à l'image originale, que les deux régions homogènes ont été identifiées de manière satisfaisante puisque la valeur du seuil trouvé $T^*=100$ se trouve proche de celle du seuil optimal $T_{opt}=102$.

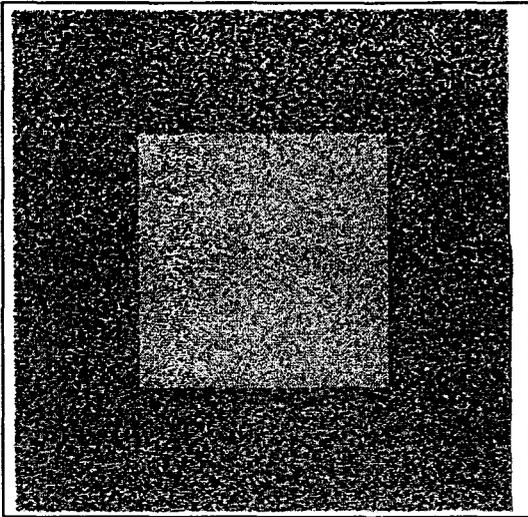


Fig. III-4 : Image synthétique.

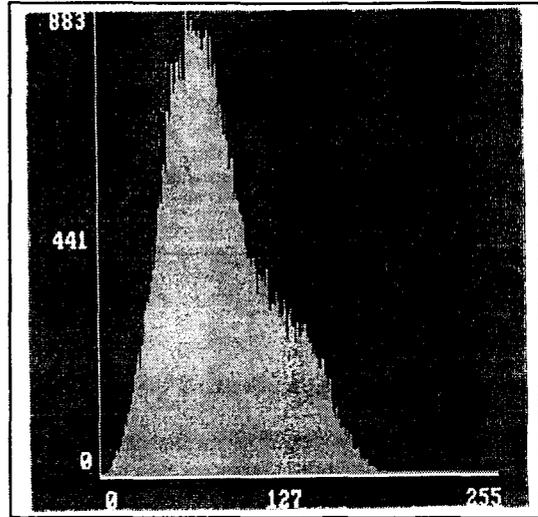


Fig. III-5 : Histogramme de l'image.

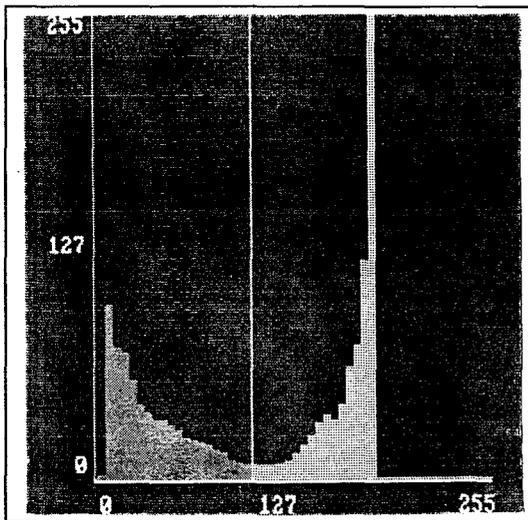


Fig. III-6 : Critère de segmentation.

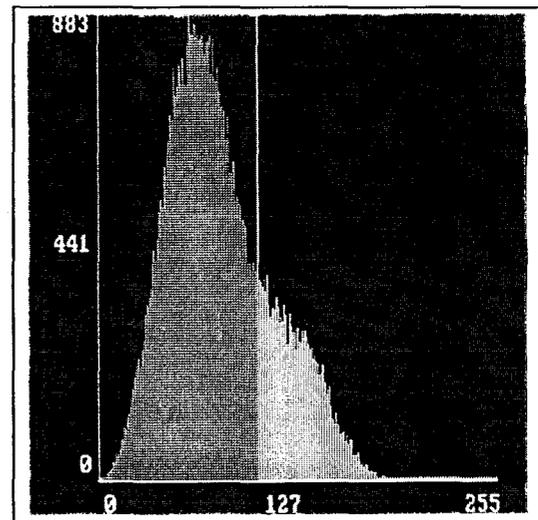


Fig. III-7 : Décomposition de l'histogramme.

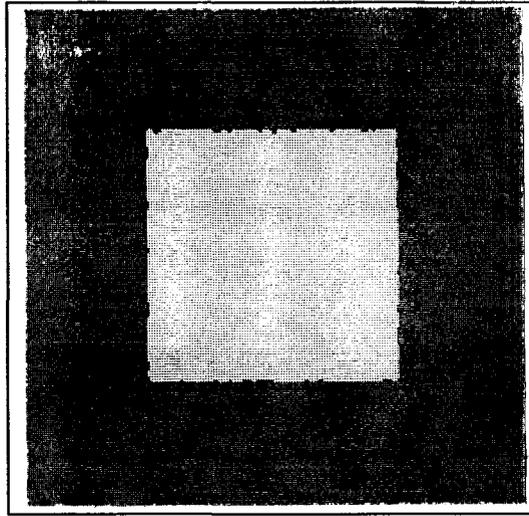


Fig. III-8 : Image filtrée/binarisée.

Il est à noter que le chevauchement des deux distributions normales de l'histogramme, relativement important, n'altère pas la qualité des résultats obtenus. Ceci représente un avantage de notre approche vis-à-vis de celle utilisée par Kittler et Illingworth [Kit-85] qui nécessite, dans ce cas, des calculs supplémentaires [Cho-89].

II-2 Classification multi-classes des points-image.

II-2-1 Principe de l'approche.

L'étude qui a été consacrée précédemment à la segmentation d'une image bimodale va maintenant être étendue au cas multimodal selon une approche itérative.

En supposant que l'histogramme des niveaux de gris d'une image se compose de Q fonctions normales de densité de probabilité, on peut choisir $Q-1$ seuils initiaux $T_1^0, \dots, T_q^0, \dots, T_{Q-1}^0$ pour décomposer arbitrairement l'image en Q classes de points $C_1^0, \dots, C_q^0, \dots, C_Q^0$ (fig. III-9). L'ensemble de ces Q classes, noté $P_0 = (C_1^0, \dots, C_q^0, \dots, C_Q^0)$, définit la segmentation initiale de l'image.

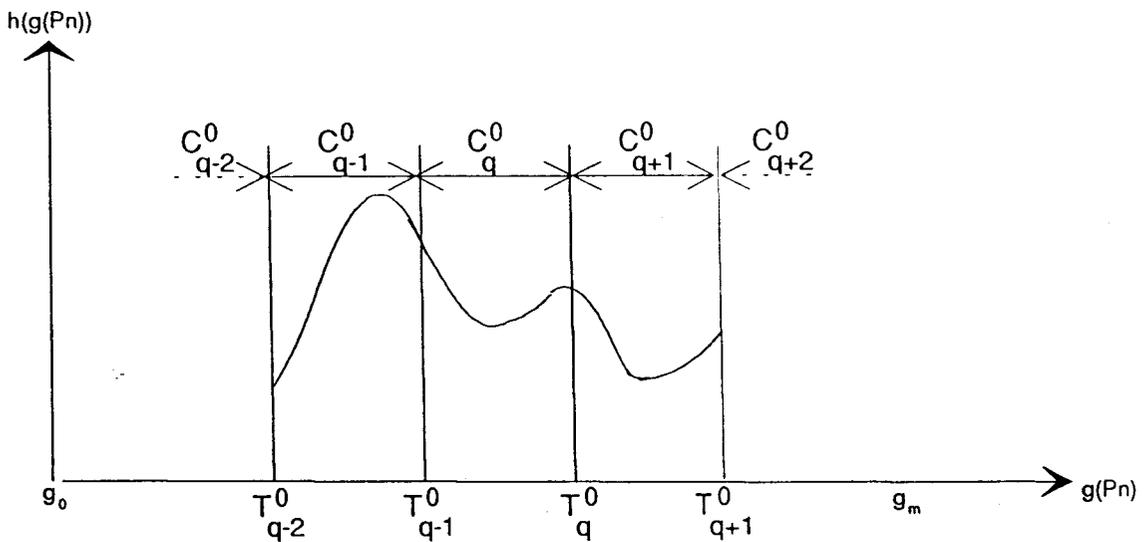


Fig. III-9 : Décomposition initiale de l'histogramme en Q classes.

Chaque seuil T_q^0 , pour $q=1,2,\dots,Q-1$, sépare l'ensemble des niveaux de gris du segment $S_q^0 = [T_{q-1}^0, \dots, T_q^0, \dots, T_{q+1}^0]$ en deux classes distinctes. La première, notée C_q^0 , regroupe les pixels dont les niveaux de gris appartiennent à l'intervalle $[T_{q-1}^0, \dots, T_q^0]$ et la seconde, notée C_{q+1}^0 , les points-image dont les niveaux de gris appartiennent à l'intervalle $[T_q^0, \dots, T_{q+1}^0]$ (fig. III-10)

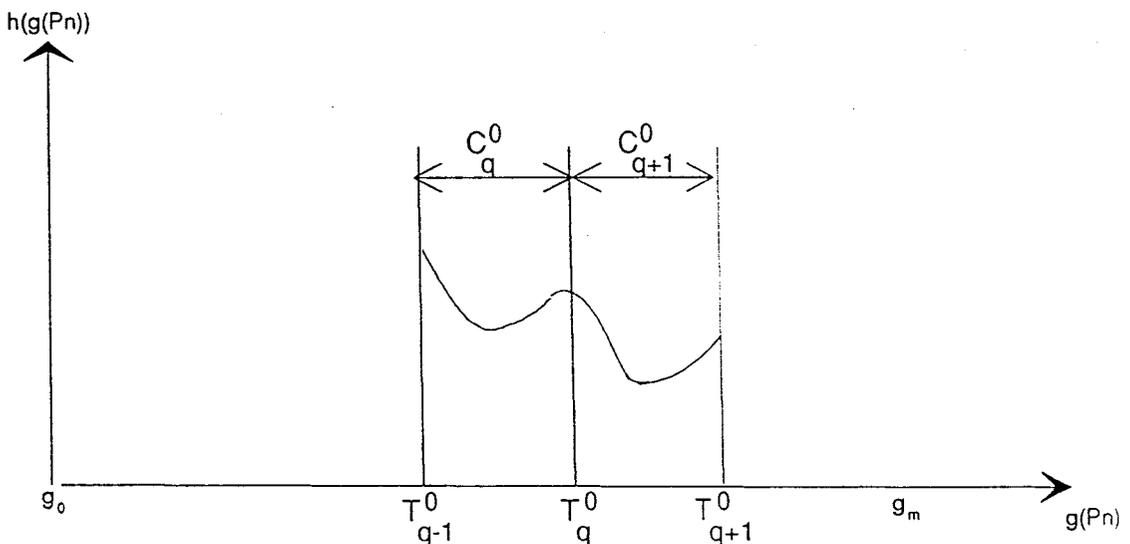


Fig. III-10 : Séparation, par le seuil T_q^0 , d'un ensemble de points en deux classes.

Sous l'hypothèse selon laquelle la distribution statistique de chaque classe suit une loi normale, le seuil T_q^0 de binarisation doit permettre d'identifier, sur la plage des niveaux de gris $S_q^0 = [T_{q-1}^0, \dots, T_q^0, \dots, T_{q+1}^0]$, deux classes de points aussi proches que possible de distributions normales. Pour que cette propriété soit vérifiée, le critère $J(T)$, défini précédemment, est appliqué sur chaque segment S_q^0 de l'histogramme.

De manière plus explicite, soit $J_q(T_q^1)$ le critère appliqué sur le $q^{\text{ème}}$ segment S_q^0 de la partition P_0 .

$J_q(T_q^1)$ s'exprime sous la forme :

$$J_q(T_q^1) = \sum_{g=T_{q-1}^0}^{T_q^0} \left[\frac{h(g(P_n))}{P_1(T_q^1)} - p(g(P_n) | 1, T_q^1) \right]^2 + \sum_{g=T_q^0}^{T_{q+1}^0} \left[\frac{h(g(P_n))}{P_2(T_q^1)} - p(g(P_n) | 2, T_q^1) \right]^2$$

avec $S_q^0 = [T_{q-1}^0, \dots, T_q^0, \dots, T_{q+1}^0]$

Le niveau de gris, pris parmi ceux de S_q^0 , qui minimise $J_q(T_q^1)$ correspond au $q^{\text{ème}}$ seuil T_q^1 de la première itération de l'algorithme (fig. III-11). De la même façon, les autres seuils $T_1^1, \dots, T_{q-1}^1, T_{q+1}^1, \dots, T_0^1$, sont déterminés en minimisant le critère sur leurs plages respectives de niveaux de gris.

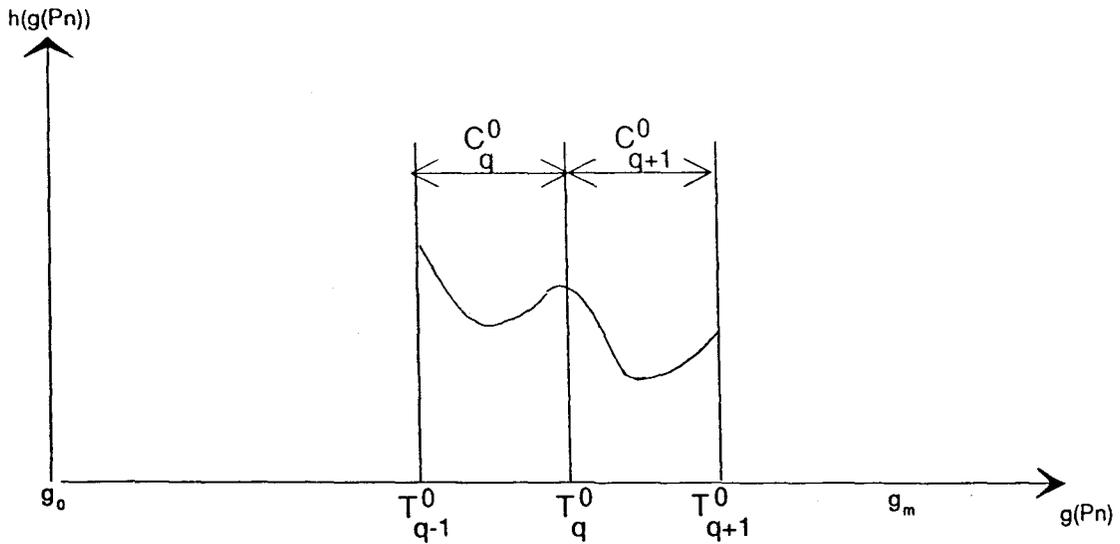


Fig. III-11 : Séparation en deux classes, par le seuil T_q^1 , du même ensemble de points que la figure III-10.

A l'issue de cette première itération, les $Q-1$ nouveaux seuils, $T_1^1, \dots, T_q^1, \dots, T_{Q-1}^1$ décomposent l'histogramme en une nouvelle partition $P_1 = (C_1^1, \dots, C_q^1, \dots, C_Q^1)$ (fig. III-12). Cette partition se trouve plus proche de l'optimale, au sens du critère, que ne l'est la partition arbitraire initiale P_0 .

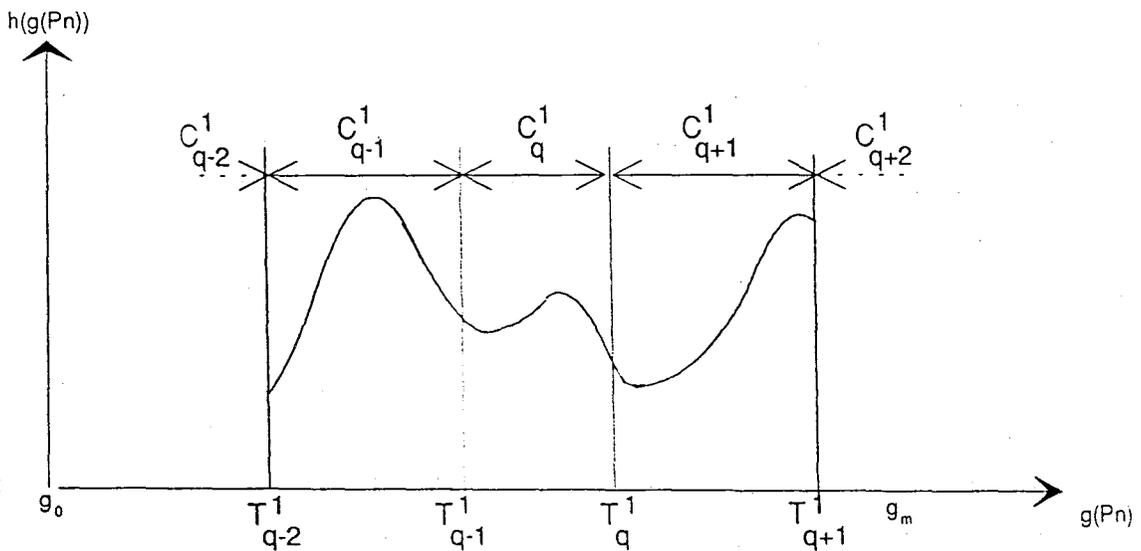


Fig. III-12 : Décomposition de l'histogramme à la première itération.

D'une manière générale, à la $k^{\text{ème}}$ itération, les $Q-1$ seuils $T_1^k, \dots, T_j^k, \dots, T_Q^k$ sont déterminés selon le principe présenté précédemment. Le procédé est itéré jusqu'à ce que les seuils trouvés soient identiques d'une itération à la suivante. Ces seuils sont

retenus pour segmenter l'image en Q types de régions homogènes.

II-2-2 Résultats expérimentaux.

La figure III-13 représente une image de format 320x200, codée sur 256 niveaux de gris. L'image a été générée par le même procédé que celui utilisé pour la première image servant d'illustration à notre approche pour la binarisation des images. Les caractéristiques statistiques de ces trois régions sont les suivantes :

	première région	deuxième région	troisième région
probabilité a priori	$P_1=0,6$	$P_2=0,2$	$P_3=0,2$
moyenne en niveau de gris	$\mu_1=65$	$\mu_2=140$	$\mu_3=190$
variance en niveau de gris	$\sigma_1=28$	$\sigma_2=37$	$\sigma_3=30$

L'histogramme se compose de trois distributions normales (fig. III-14). Chacune d'elle reflète la distribution des niveaux de gris des points-image d'un type particulier.

Une décomposition initiale de l'histogramme selon deux seuils $T_1^0=40$ et $T_2^0=60$ permet de diviser arbitrairement l'image en 3 classes de points C_1^0 , C_2^0 et C_3^0 (fig. III-15). Leurs niveaux de gris appartiennent respectivement aux trois gammes de niveaux de gris $[0, \dots, 40]$, $[41, \dots, 60]$ et $[61, \dots, 255]$.

Le critère $J_q(T)$, pour $q=1, 2, \dots, Q$, appliqué sur les deux segments $S_1^0=[0, \dots, 60]$ et $S_2^0=[40, \dots, 255]$, engendre une nouvelle partition $P_1=(C_1^0, C_2^0, C_3^0)$ plus proche d'une partition en composantes normales que la première partition P_0 (fig. III-16). Cette partition de l'histogramme est issue des deux seuils de scission $T_1^1=37$ et $T_2^1=112$.

L'algorithme est ensuite itéré sur cette nouvelle partition P_1 . Il en résulte deux nouveaux seuils $T_1^1=67$ et $T_2^1=157$ qui définissent la partition P_2 de l'histogramme (fig. III-17).

Si une quatrième itération est appliquée, les deux seuils obtenus sont identiques à ceux résultants de la troisième itération. Ces deux seuils de décomposition, $T_1^3=102$ et $T_2^3=162$, sont donc ceux retenus pour la décomposition de l'histogramme en composantes normales (fig. III-18). Il est à noter que la segmentation résultante de l'image (fig. III-19) se trouve très proche de la segmentation optimale puisque les valeurs de seuils T_1^3 et T_2^3 sont proches des valeurs 100 et 158 des seuils optimaux déterminés par la théorie de la décision.

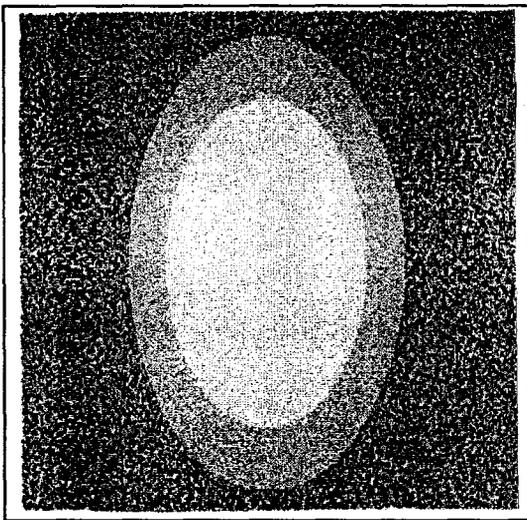


Fig. III-13 : Image originale.

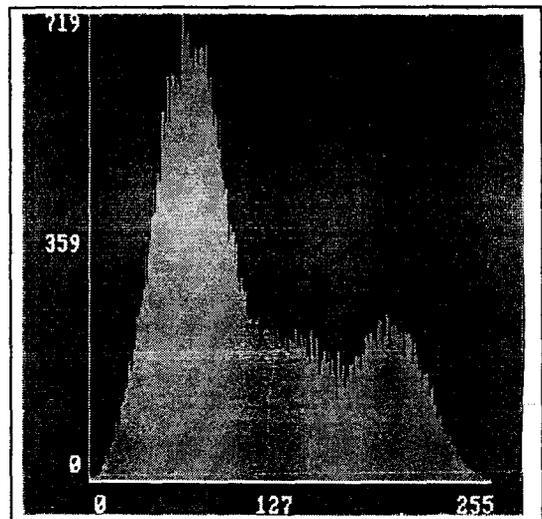


Fig. III-14 : Histogramme de l'image.

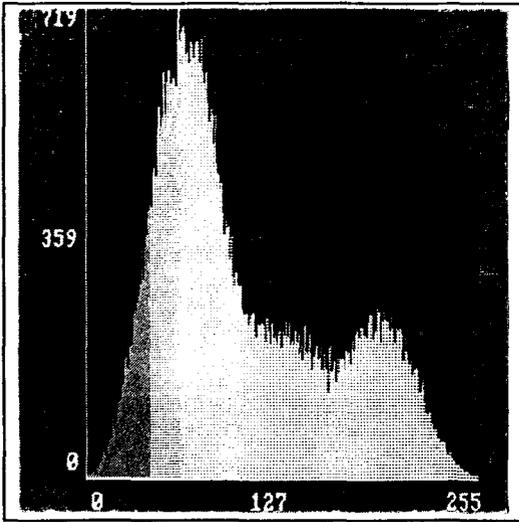


Fig. III-15 : Partition initiale.

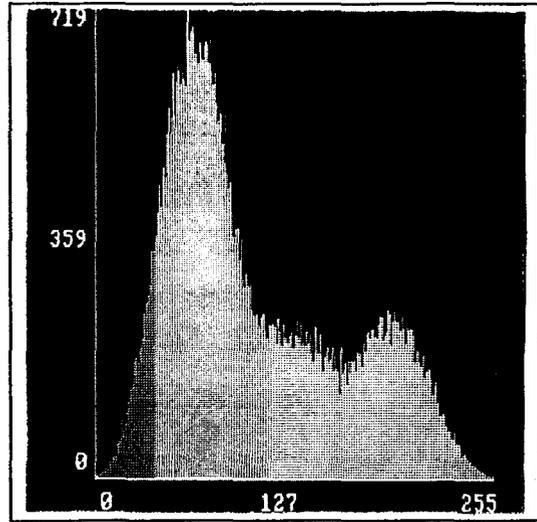


Fig. III-16 : Première partition.

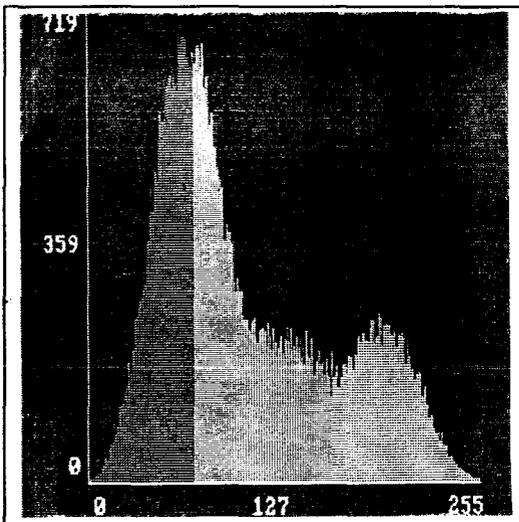


Fig. III-17 : Seconde partition.

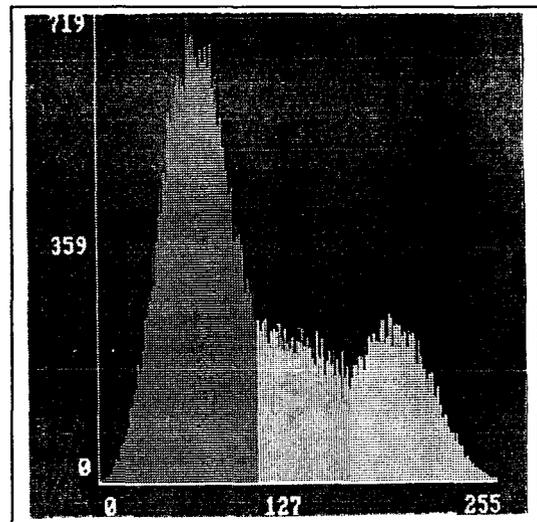


Fig. III-18 : Troisième partition.

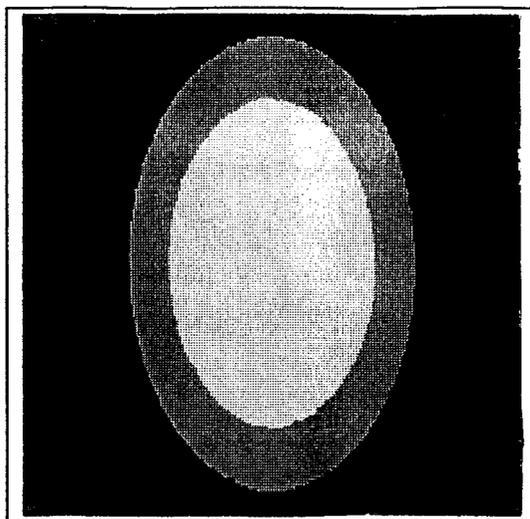


Fig. III-19 : Image filtrée/binarisée.

Afin de montrer que les seuils initiaux utilisés pour l'initialisation de cet algorithme itératif n'ont pas une importance cruciale sur le résultat final, il a été jugé utile de prendre différents jeux de seuils (T_1^0, T_2^0) et de comparer les résultats obtenus (fig. III-20).

	Etape initiale	Première itération	Deuxième itération	Troisième itération
Premier exemple	$T_1^0 = 40$ $T_2^0 = 60$	$T_1^1 = 37$ $T_2^1 = 112$	$T_1^2 = 67$ $T_2^2 = 157$	$T_1^3 = 102$ $T_2^3 = 162$
Deuxième exemple	$T_1^0 = 80$ $T_2^0 = 105$	$T_1^1 = 62$ $T_2^1 = 157$	$T_1^2 = 102$ $T_2^2 = 162$	Seuils identiques à la deuxième itération
Troisième exemple	$T_1^0 = 120$ $T_2^0 = 140$	$T_1^1 = 102$ $T_2^1 = 162$	Seuils identiques à la première itération	Seuils identiques à la première itération
Quatrième exemple	$T_1^0 = 75$ $T_2^0 = 125$	$T_1^1 = 97$ $T_2^1 = 162$	$T_1^2 = 102$ $T_2^2 = 162$	Seuils identiques à la deuxième itération

Fig. III-20: Résultats obtenus pour différents jeux de seuils initiaux.

Mis à part le nombre d'itérations, on constate que les seuils finaux sont identiques quelque soit le jeu de seuils initiaux utilisé. Ceci montre la supériorité de cette technique itérative vis-à-vis d'autres méthodes itératives pour lesquelles le résultat final dépend fortement des seuils initiaux [Rid-78, Tru-79].

En conclusion, cette méthode de segmentation par classification se révèle efficace si la classification des niveaux de gris permet, comme dans notre exemple, de mettre en évidence les régions homogènes qui composent l'image. Dans ce cas d'images comprenant plusieurs régions de niveaux de gris moyens différents, l'approche de segmentation donne de bons résultats comme le montrent les résultats obtenus sur l'image présentée précédemment.

Cependant, lorsque l'image à segmenter présente des régions de niveaux de gris moyens similaires ou lorsqu'une région recouvre la quasi totalité de la surface de l'image, l'approche proposée se révèle inutilisable puisque l'histogramme de telles images ne présente qu'un seul mode.

Dans ce cas, il peut être intéressant d'associer à chacun des points-image un vecteur regroupant plusieurs attributs afin d'améliorer la discrimination entre les différentes régions constituant l'image. L'extension de l'approche de classification au cas multidimensionnel fait l'objet du paragraphe suivant.

II-3 Approche multidimensionnelle pour la classification des points-image.

Lorsqu'on envisage une classification automatique, il faudrait théoriquement examiner toutes les façons de classer les données puis retenir celle qui, parmi celles possibles, optimise les critères mis en jeu dans la procédure. Face à cette situation, on est généralement amené à opter pour une solution sous-optimale qui nécessite des hypothèses de base plus ou moins contraignantes [Kam-72, Dub-80]. A cela, nous préférons utiliser notre critère dans le cadre d'une procédure de classification interactive afin de guider l'opérateur effectuant l'analyse de l'échantillon.



II-3-1 Position du problème.

On suppose que A attributs ont été relevés sur chaque point P_n de l'image que l'on désire segmenter. Ces A attributs constituent l'observation X_n associée au point P_n , qui s'écrit :

$$X_n = [X_1, X_2, \dots, X_A]^T.$$

L'échantillon X des N observations multidimensionnelles associées aux points-image peut être représenté dans un espace Euclidien à A dimensions, défini par A axes relatifs aux A attributs associés à chaque point-image. Il s'agit maintenant d'analyser la structure de l'échantillon dans l'espace multidimensionnel des attributs dans le but d'obtenir une classification significative des points-image constituant l'échantillon. Mais cette représentation multidimensionnelle des données à analyser échappe à tout opérateur humain si la dimension de l'espace des attributs est supérieure à trois. Pour cette raison, de nombreuses techniques d'analyse de données multidimensionnelles consistent à réduire la dimension des observations à deux dimensions afin de pouvoir faire appel aux capacités de classification de l'opérateur humain.

II-3-2 Réduction de la dimension de l'espace des attributs.

La technique la plus couramment utilisée pour réduire la dimension des données est certainement l'analyse en composantes principales [Coo-71, Seb-84]. Lorsque cette technique ne permet pas de réduire suffisamment la dimension, du fait que trop d'informations seraient perdues si on ne conservait que deux axes principaux, certains auteurs proposent d'utiliser l'analyse en composantes principales comme point de départ pour une technique plus élaborée [Gow-66, Kru-77]. Il s'agit alors de minimiser des critères qui indiquent comment la répartition des observations dans le plan est le reflet de la répartition des observations d'origine. On peut, par exemple, tenter de conserver la relation d'ordre qui existe entre les distances inter-observations au niveau des distances entre les observations projetées sur le plan [Kru-64, She-62].

D'autres auteurs cherchent à préserver la séparabilité entre les classes en représentant les données en deux dimensions [Sam-70, Fuk-71].

Cependant, le rôle de ces approches se limite à réduire la dimension de l'espace de représentation des données, laissant au système visuel humain le soin d'achever la classification.

Le paragraphe suivant présente notre contribution à l'enrichissement d'un logiciel de classification interactive de données multidimensionnelles conçu pour représenter les données de dimension A sur un plan afin de fournir une indication sur la qualité de la classification interactive effectuée par l'opérateur.

II-3-3 Présentation du logiciel interactif de classification.

Les données multidimensionnelles de l'échantillon analysé peuvent être visualisées sur un plan au moyen d'un logiciel élaboré par F. Esson pour la classification interactive des données [Ess-89]. Pour cela, on associe à chaque observation multidimensionnelle X_n une image bidimensionnelle dans le plan, dont les coordonnées sont calculées par rapport à un référentiel orthonormé dit "référentiel d'observation". Celui-ci est défini par son origine O et un vecteur unitaire de référence \vec{V}_{ref} . Dans le plan de représentation, la distance Euclidienne $p=d(O\vec{X}_n)$ de l'observation X_n par rapport à l'origine du référentiel et l'angle que fait le vecteur $O\vec{X}_n$ avec celui de référence \vec{V}_{ref} représentent l'abscisse et l'ordonnée respectives de l'image de l'observation X_n .

Ce logiciel de visualisation offre la possibilité de faire évoluer l'origine O du repère ainsi que la direction du vecteur de référence \vec{V}_{ref} . Ainsi, tout comme procède un individu en se déplaçant et orientant son regard vers une direction privilégiée, une configuration appropriée Position/Angle du référentiel peut faciliter une discrimination visuelle des données.

Bien que ce mode de représentation des données sur un plan présente l'avantage d'offrir à l'analyste un support de réflexion qui permet de mieux cerner la structure sous-jacente des données, l'exploitation des résultats de la classification d'un échantillon de points basée sur les appréciations et la perception visuelle d'un analyste exige beaucoup de prudence, car le caractère très subjectif de ce type de procédure peut nuire à la qualité de la classification obtenue. C'est pourquoi nous proposons d'utiliser notre critère de qualité, généralisé au cas multidimensionnel, afin d'aider l'analyste à

porter un jugement plus rationnel sur sa démarche intuitive.

III STRATEGIE UTILISEE POUR GUIDER LA CLASSIFICATION INTERACTIVE

III-1 Principe de l'approche.

Le principe de l'analyse multidimensionnelle est une généralisation de celle de la classification des points-image caractérisés par un seul attribut. Dans le cas présent, le critère quadratique J représente l'erreur quadratique entre la distribution de chaque classe créée par l'analyste avec le logiciel interactif et son modèle normal.

Ce critère permettant de mesurer la qualité de la décomposition des fonctions de densité de probabilité en composantes normales se présente donc sous la forme :

$$J = \sum_{q=1}^Q \left[\sum_{X_n \in C_q} (p(X_n) - p(X_n | C_q))^2 \right]$$

où $p(X_n)$ représente la valeur de la fonction de densité de probabilité pour l'observation X_n associée au point P_n de l'image et $p(X_n | C_q)$ celle fournie par le modèle normal déterminé à partir de l'ensemble des observations assignées à la classe C_q .

La distribution normale $p(X_n | C_q)$ prend, pour l'observation X_n , la forme suivante :

$$p(X_n | C_q) = \frac{1}{(2.\pi)^{\frac{A}{2}} [S_q]^{\frac{1}{2}}} \cdot \exp\left[-\frac{1}{2} [X_n - \bar{X}_q] \cdot S^{-1} \cdot [X_n - \bar{X}_q]\right]$$

où

$$\left\{ \begin{array}{l} A = \text{nombre d'attributs de chaque observation.} \\ \bar{X}_q = \text{vecteur moyenne de la classe } C_q. \\ S_q^{-1} = \text{matrice inverse diagonale de covariance de la classe } C_q. \\ [S_q] = \text{déterminant de la matrice de covariance de la classe } C_q. \end{array} \right.$$

Ne disposant pas de la valeur $p(X_n)$ de la fonction réelle de densité de probabilité, cette loi est estimée pour chaque observation X_n selon une technique classique d'estimation non paramétrique que nous allons formuler au prochain paragraphe.

Le critère J devient alors :

$$J = \sum_{q=1}^Q \left[\sum_{X_n \in C_q} (\hat{p}(X_n) - p(X_n | C_q))^2 \right]$$

où $\hat{p}(X_n)$ est la valeur estimée de la fonction de densité de probabilité au point où se situe l'observation X_n .

III-2 Estimation de la fonction de densité de probabilité.

On démontre, dans [Dub-90], que :

$\hat{p}(X_n) = \frac{K}{N.V[D]}$ où K est le nombre d'observations, parmi les N disponibles, situées dans un domaine D de volume $V[D]$ de l'espace des attributs, centré sur l'observation

X_n constitue une estimation simple de la densité de probabilité pour l'observation X_n .

La méthode du Noyau due à Parzen [Par-62] et celle des K-plus proches voisins [Lof-65] sont les deux méthodes les plus répandues qui répondent aux conditions nécessaires de convergence de cet estimateur.

L'idée fondamentale associée à la méthode du noyau consiste à pondérer la contribution de chaque observation à l'estimation de $\hat{p}(X_n)$ en fonction de sa distance par rapport à l'observation X_n . L'estimateur prend alors la forme :

$$\hat{p}(X_n) = \frac{1}{N} \sum_{m=1}^N \frac{1}{h_N} \cdot \varphi\left(\frac{X_n - X_m}{h_N}\right)$$

où le paramètre h_N est appelé largeur de la fenêtre de l'estimateur et $\varphi(u)$ le noyau de la fenêtre.

Différents types de fonctions $\varphi(u)$ assurent la convergence de l'estimateur. Le noyau cubique est le plus utilisé pour des considérations de programmation simple sur ordinateur.

Il est cependant bien connu des praticiens que si h_N est trop petit, l'estimation présente trop de variabilité et que s'il est trop grand, l'estimation, trop lissée, manque de résolution [Dud-73].

Pour pallier cette difficulté, le principe de la méthode des K plus proches voisins fixe a priori un nombre K de voisins du point où on désire estimer la densité et fait ensuite croître le volume $V[D]$ jusqu'à ce que le domaine D englobe effectivement les K plus proches voisins du point considéré [Lof-65]. La taille du domaine s'ajuste donc à la densité locale des observations autour du point considéré puisqu'une densité relativement faible nécessite un domaine de taille assez grande afin qu'il puisse effectivement englober les K voisins et, à l'inverse, la taille du domaine D est faible lorsque la densité locale est plus élevée.

Ces raisons nous amènent donc à retenir la méthode des K plus proches voisins pour estimer la fonction de densité de probabilité en chaque observation de l'espace

des attributs.

L'estimateur $\hat{p}(X)$ pour l'observation X_n s'écrit donc :

$$\hat{p}(X_n) = \frac{K}{N \cdot V[D]}$$

où le nombre K est fixé par l'analyste. N est le nombre d'observations disponibles qui est en fait le nombre de points-image à classer et $V[D]$ est le volume du domaine D englobant les K observations les plus proches de X_n .

Pour des raisons d'isotropie, le domaine D est pris de forme sphérique. Le volume de l'hypersphère de centre X_n et de rayon $d_{20}(X_n)$, s'écrit sous la forme:

$$V[D] = \frac{d_{20}(X_n)^A \cdot \pi^{\frac{A}{2}}}{\gamma\left(\frac{A}{2} + 1\right)}$$

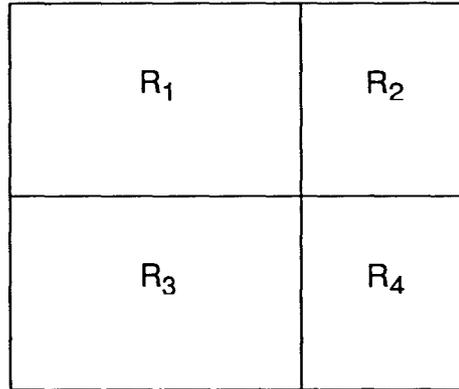
où $d_{20}(X_n)$ est la distance euclidienne entre le point X_n de l'espace des attributs et son $K^{\text{ème}}$ plus proche voisin, A la dimension des observations et γ la fonction Gamma telle que :

$$\text{si } A \text{ est pair} \quad \gamma\left(\frac{A}{2} + 1\right) = \left(\frac{A}{2}\right)!$$

$$\text{si } A \text{ est impair} \quad \gamma\left(\frac{A}{2} + 1\right) = \frac{(A+1)!}{2^{(A+1)}} \cdot \left(\frac{A+1}{2}\right)! \sqrt{\pi}$$

IV RESULTATS EXPERIMENTAUX.

L'image synthétique servant d'illustration à notre algorithme se compose de quatre régions rectangulaires (fig. III-21) disposées selon le schéma suivant :



Chaque région est constituée de points dont les niveaux de gris sont distribués sous une forme normale avec les caractéristiques suivantes :

	région R ₁	région R ₂	région R ₃	région R ₄
moyenne en niveau de gris.	$\mu=6,9$	$\mu=7$	$\mu=2$	$\mu=15$
variance en niveau de gris	$\sigma=2$	$\sigma=2,2$	$\sigma=2,7$	$\sigma=2$

Quelque soit la valeur choisie pour le seuil de binarisation, la binarisation à un seuil fixe échoue inévitablement. La figure III-22 montre le type d'image binarisée que l'on peut obtenir.

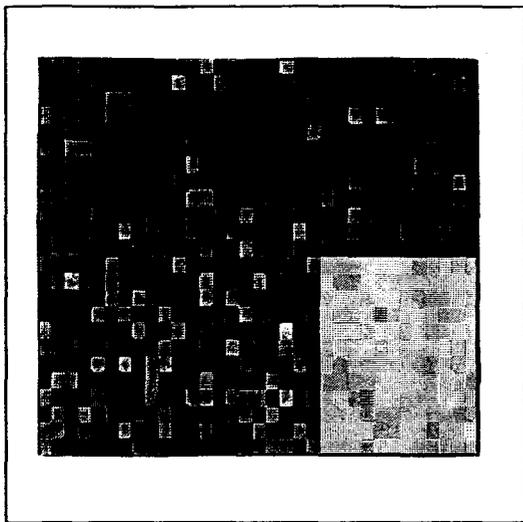
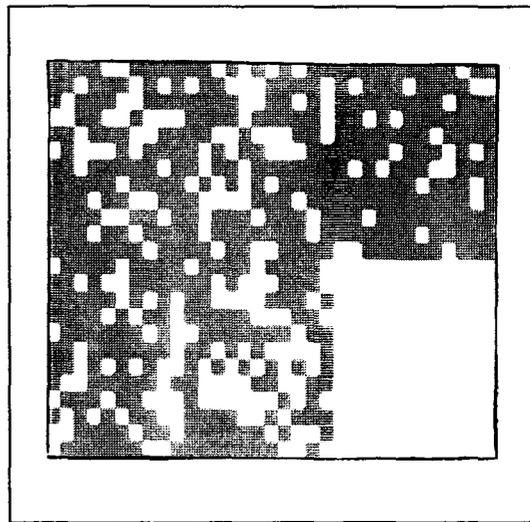


Fig. III-21 : Image originale.



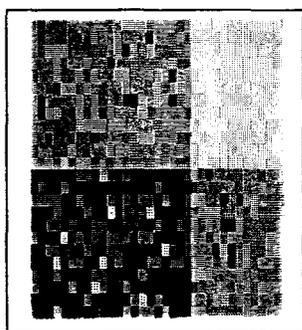
*Fig. III-22 : Image originale seuillée
au seuil 50*

Puisqu'aucune valeur de seuil ne nous permet d'identifier correctement les points appartenant à l'une des quatre régions R_1 , R_2 , R_3 ou R_4 , un seuillage de l'image à trois niveaux de seuils ne peut donc pas permettre d'identifier les 4 régions de l'image.

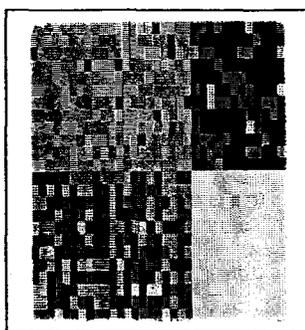
Les points de l'image ont été, de ce fait, caractérisés par quatre variables aléatoires supplémentaires de distributions normales (fig. III-23).

Les cinq attributs des points-image ont les caractéristiques suivantes :

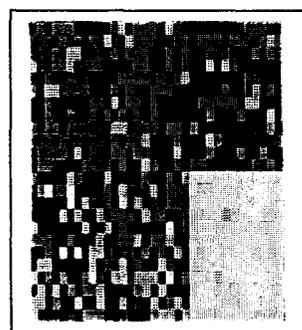
	région R_1	région R_2	région R_3	région R_4
moyenne en niveau de gris.	$\mu_1=3,1$	$\mu_1=9,9$	$\mu_1=10$	$\mu_1=1,9$
variance en niveau de gris.	$\sigma_1=1,8$	$\sigma_1=1,8$	$\sigma_1=3,1$	$\sigma_1=2,2$
moyenne en niveau de gris.	$\mu_2=15$	$\mu_2=6,9$	$\mu_2=3,9$	$\mu_2=2,1$
variance en niveau de gris.	$\sigma_2=1,8$	$\sigma_2=2,2$	$\sigma_2=2,7$	$\sigma_2=2,3$
moyenne en niveau de gris.	$\mu_3=6,9$	$\mu_3=7$	$\mu_3=2$	$\mu_3=15$
variance en niveau de gris.	$\sigma_3=2$	$\sigma_3=2,2$	$\sigma_3=2,7$	$\sigma_3=2$
moyenne en niveau de gris.	$\mu_4=9,9$	$\mu_4=8,2$	$\mu_4=19,9$	$\mu_4=15$
variance en niveau de gris.	$\sigma_4=1,9$	$\sigma_4=1,9$	$\sigma_4=3,1$	$\sigma_4=2,4$
moyenne en niveau de gris.	$\mu_5=14,8$	$\mu_5=2,9$	$\mu_5=2,9$	$\mu_5=1,9$
variance en niveau de gris.	$\sigma_5=2,2$	$\sigma_5=1,7$	$\sigma_5=3,9$	$\sigma_5=2,4$



(a)



(b)



(c)

Fig. III-23 : Image originale avec cinq attributs.

a- : Premier attribut.

b- : Deuxième attribut.

c- : Troisième attribut

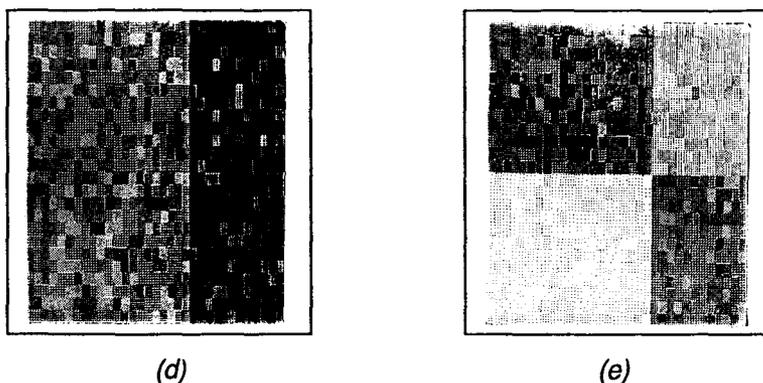


Fig. III-23 : Image originale avec cinq attributs.

d- : Quatrième attribut.

e- : Cinquième attribut.

Ces données sont ensuite visualisées au moyen du logiciel interactif de F. Esson que nous avons présenté dans le paragraphe II-3-c. La figure III-24 indique la représentation 2D obtenue en prenant pour référentiel d'observation l'origine de l'espace de représentation des données multidimensionnelles et le vecteur unitaire de l'axe associé au premier attribut. Dans le cas présent, ce logiciel permet de représenter ces données de dimension cinq sur un plan. Ce type de support visuel a ainsi l'avantage, pour un opérateur humain, de mieux cerner la structure sous-jacente des données multidimensionnelles. La représentation des données de la figure III-25, associée à un repère d'observation différent, fait apparaître quatre classes de données alors que la figure III-24 n'en fait apparaître que trois.

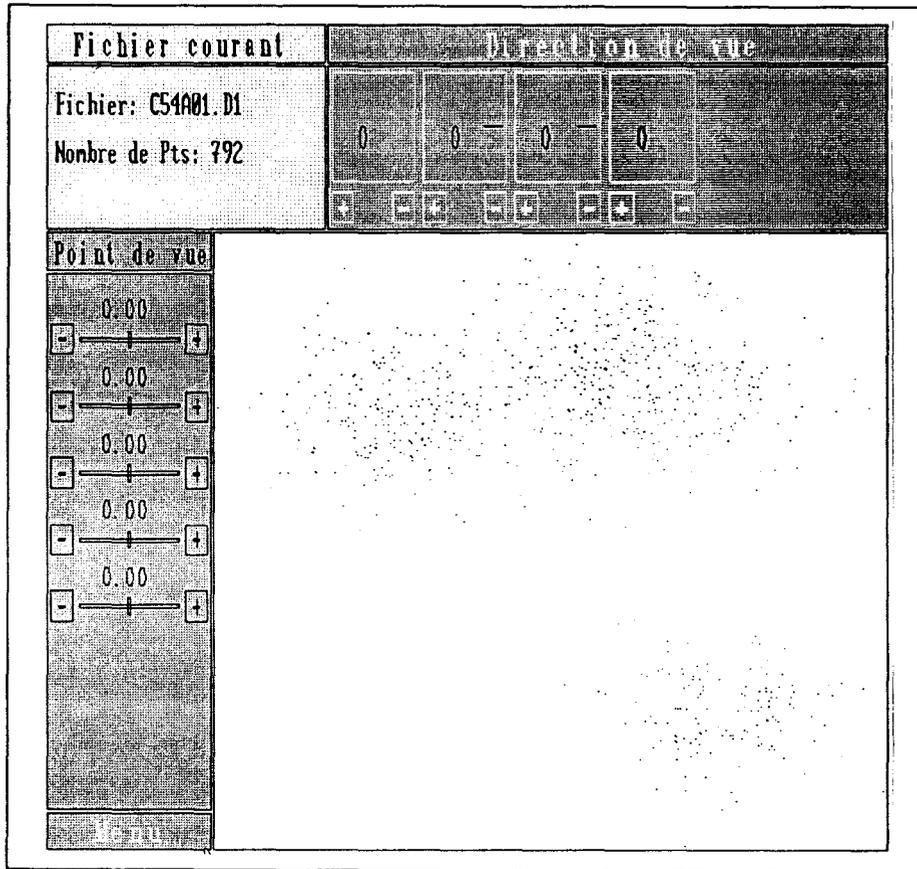


Fig. III-24 : Visualisation des données en 2D avec un repère d'observation confondu avec le repère de l'espace de représentation des données.

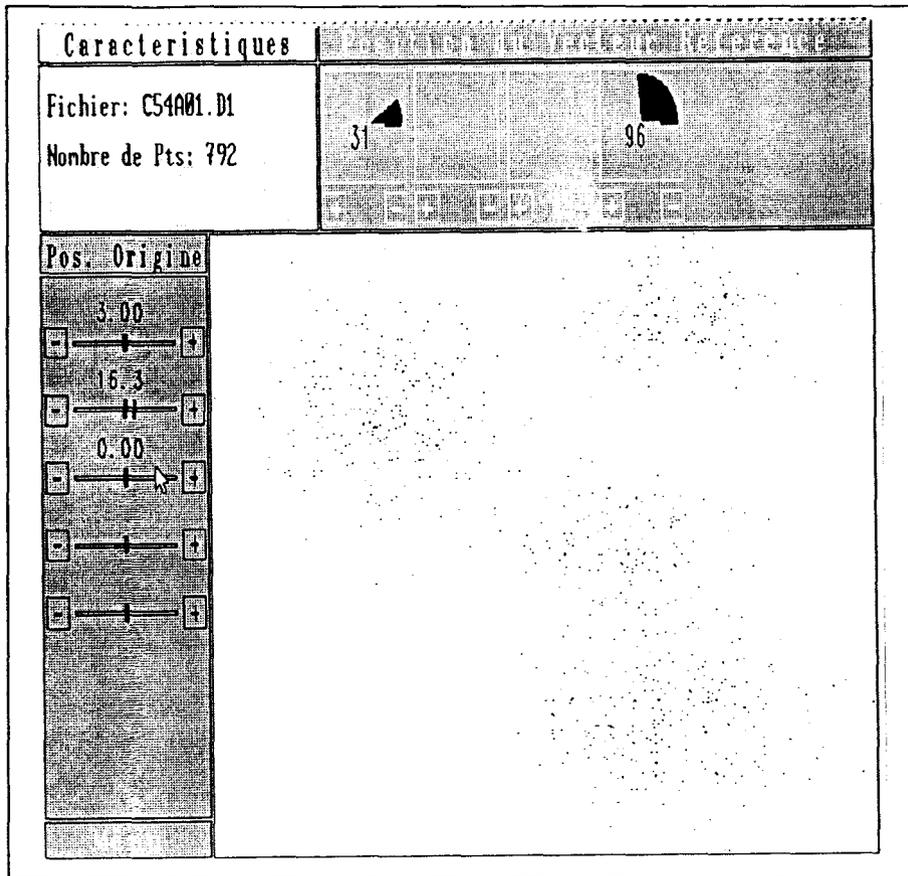


Fig. III-25 : Visualisation des données associées à un repère d'observation différent du repère de l'espace de représentation des données.

Chaque groupe de données est ensuite encerclé par un polygone construit à l'aide de la souris pour ne constituer qu'une classe (fig. III-26). Dans notre cas, les données sont réparties entre quatre classes distinctes $C_1^0, C_2^0, C_3^0, C_4^0$. Sur les données de chacune de ces classes C_q^0 , pour $q=1,2,3,4$, la différence quadratique entre la fonction de densité de probabilité estimée associée et son modèle normal :

$$\sum_{X_n \in C_q} (\hat{p}(X_n) - p(X_n | C_q))^2$$

est calculée, avec

$$p(X_n | C_q) = \frac{1}{(2.\pi)^{\frac{A}{2}} [S_q]^{\frac{1}{2}}} \cdot \exp \left[-\frac{1}{2} [X_n - \bar{X}_q] \cdot S_q^{-1} \cdot [X_n - \bar{X}_q] \right]$$

où $\left\{ \begin{array}{l} A = \text{nombre d'attributs de chaque observation.} \\ \bar{X}_q = \text{vecteur moyenne de la classe } C_q. \\ S_q^{-1} = \text{matrice inverse diagonale de covariance de la classe } C_q. \\ [S_q] = \text{déterminant de la matrice de covariance de la classe } C_q. \end{array} \right.$

et $\hat{p}(X_n) = \frac{K}{N.V[D]}$ où K a été fixé à la valeur 20.

La somme de ces quatre différences, correspondant à la valeur du critère J associée à cette classification interactive, prend la valeur 0,007.

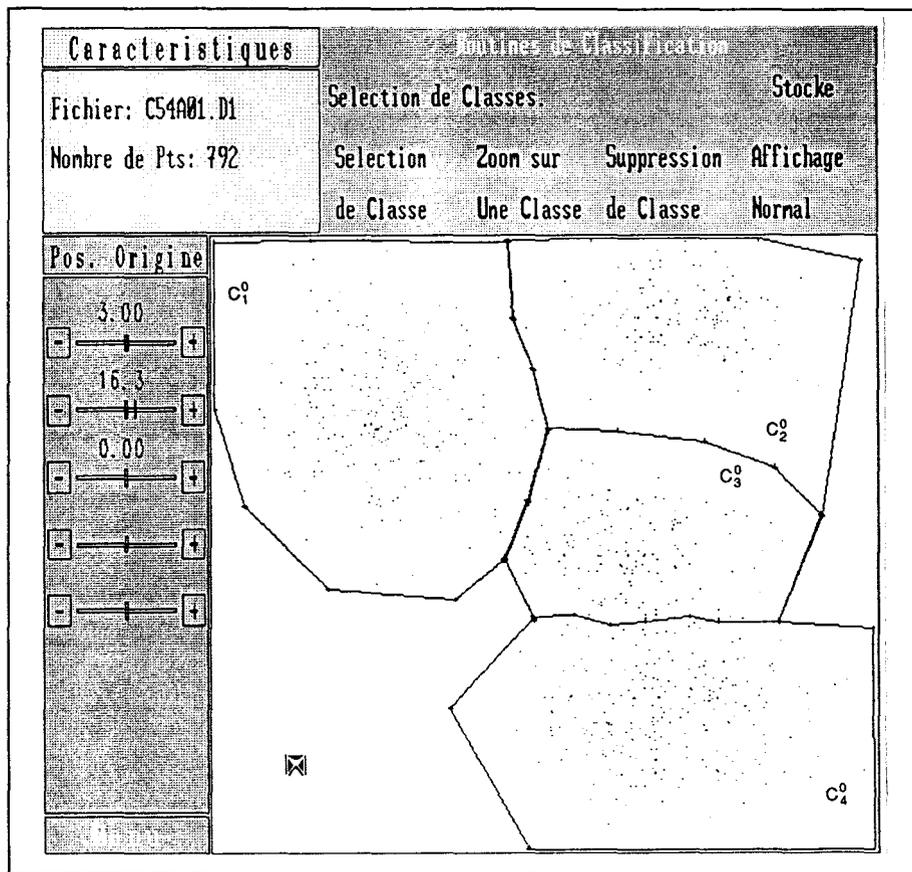


Fig. III-26 : Classification interactive.

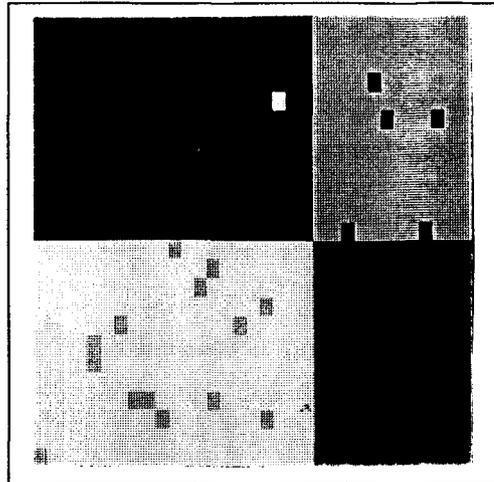


Fig. III-27 : Segmentation correspondante de l'image.

La segmentation correspondante de l'image fait apparaître, comme l'indique la figure III-27 ci-dessus un mauvais étiquetage de certains points-image. Afin d'obtenir une meilleure classification des données et par conséquent une segmentation plus significative de l'image, il convient de modifier la position et l'angle de vue du référentiel de représentation afin de mieux séparer les classes des données visualisées. Comme en témoigne la figure III-28, la nouvelle configuration du référentiel permet de mieux distinguer les classes de données en présence. Le critère évalué sur la classification de la figure III-29 prend la valeur $J=0.0045$, inférieure à $J=0.007$, correspondant à la classification précédente. Cette classification interactive des données aboutit à une segmentation de l'image sans erreur d'étiquetage (fig. III-30) .

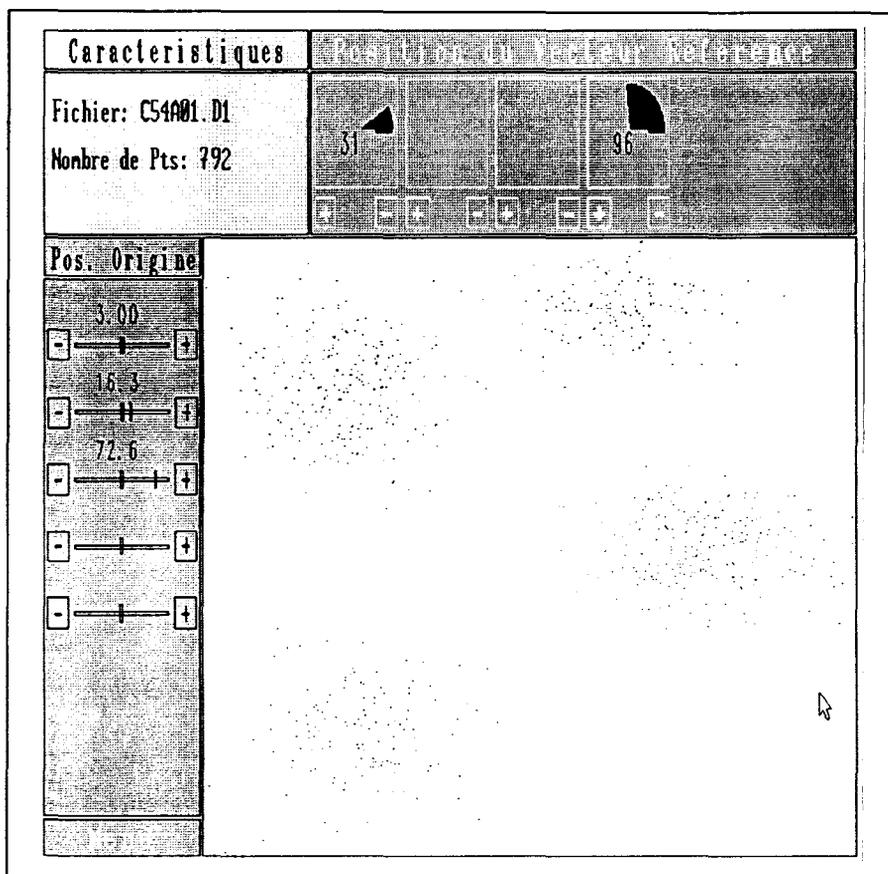


Fig. III-28 : Visualisation des données associée à un autre repère.

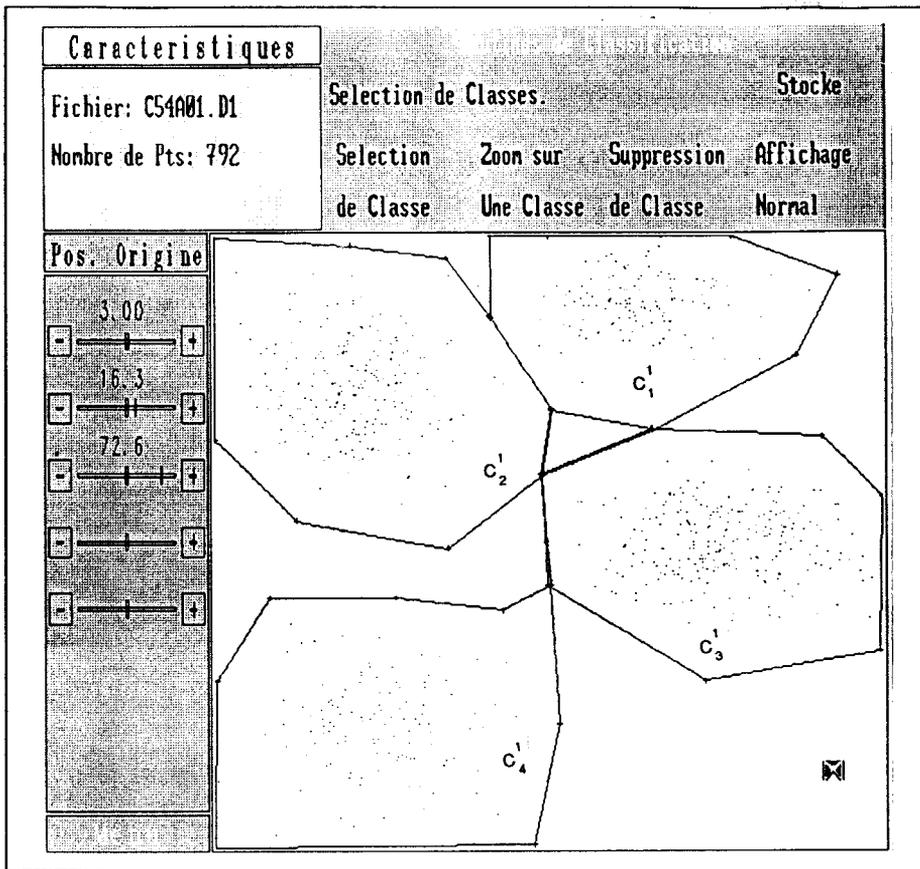


Fig. III-29 : Classification interactive des données.

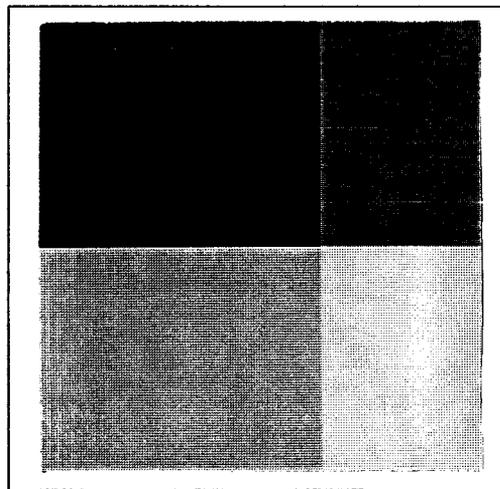


Fig. III-30 : Segmentation correspondante de l'image.

L'affichage de la valeur du critère J indiquant l'adéquation entre les classes sélectionnés itérativement par l'analyste et des modèles gaussiens donne une indication précieuse quant à la qualité de la classification effectuée par l'opérateur. Ce dernier peut donc améliorer ses performances en vérifiant si les valeurs du critère croient ou décroissent entre deux classifications différentes. Un voyant bicolore rouge/vert permet d'indiquer clairement dans quel sens varie cet indicateur de qualité de la classification.

En conclusion, l'image que nous avons étudiée montre l'importance cruciale de la discrimination des points-image sur la qualité de la segmentation. Nous avons vu qu'un seul attribut n'apporte pas une discrimination suffisante des points-image pour une segmentation correcte de l'image en régions homogènes. C'est la raison pour laquelle les points de l'image ont été caractérisés par plusieurs attributs. Le problème de la segmentation de l'image, vu sous l'angle de la classification, a ainsi été rendu possible grâce à la caractérisation multidimensionnelle des points de l'image.

IV CONCLUSION.

Nous avons vu que notre approche de segmentation par seuillage global repose sur l'hypothèse que le choix des seuils peut uniquement s'appuyer sur la prise en compte de l'intensité lumineuse de l'image. La segmentation d'une image, déduite d'une telle analyse, débouche sur une identification des distributions du mélange étudié. Cette analyse n'est cependant pas une tâche toujours facile. Il se peut, en effet, que le niveau de gris ne soit pas, à lui seul, un attribut suffisamment discriminant. Un jeu d'attributs relevé sur chaque point-image contribue souvent à lever l'ambiguïté sur l'appartenance des points aux régions existantes. Cette alternative, appliquée avec succès sur une image dans ce chapitre, présente cependant un défaut majeur susceptible de dégrader la qualité des résultats obtenus.

En effet, le principal inconvénient de notre approche, ainsi que celui de la plupart des approches de classification, vient du manque total de la prise en compte, dans la procédure de sélection des seuils, des relations spatiales existantes entre les points-image au sein de chaque région homogène. En effet, l'analyse de la connexité des points n'entre qu'en second lieu afin de reconstituer les régions identifiées dans l'image. Or, la considération de ces relations spatiales est essentielle afin d'éviter que l'on

identifie des ensembles de points appartenant à une même classe, mais qui se retrouvent en fait éclatés en plusieurs morceaux ou, dans le pire des cas, entièrement disséminés sur toute l'image. Dans le cas défavorable où aucune cohésion spatiale n'existe entre les points d'une même classe identifiée, l'image segmentée I_s présente un aspect global difficile à interpréter. Nous allons, dans le chapitre suivant, étudier les approches par extraction de régions qui permettent de remédier à ce défaut.

**DEUXIEME PARTIE : LES APPROCHES DE
SEGMENTATION
PAR EXTRACTION DES REGIONS.**

IV - LA SEGMENTATION DES IMAGES PAR EXTRACTION DES REGIONS -

LA SEGMENTATION DES IMAGES

PAR EXTRACTION DES REGIONS.

I INTRODUCTION.

Pour remédier au défaut commun à de nombreuses approches de segmentation, telles que les techniques qui opèrent par classification des points de l'image, une alternative intéressante consiste à évaluer les seuils de segmentation en utilisant conjointement les propriétés statistiques relevées sur les points-image et les relations spatiales existantes entre eux. Les procédures de segmentation qui utilisent cette stratégie sont communément appelées les procédures de segmentation par extraction de régions.

Différentes procédures se dégagent de la littérature selon la manière de combiner ces deux propriétés au cours du processus de segmentation. Elles se décomposent principalement en trois approches qui sont l'approche de segmentation par divisions, celle par fusions tandis que la troisième combine les approches par fusions et divisions. Les principes fondamentaux sur lesquels reposent chacune de ces approches sont développés en début de ce chapitre.

Pour des raisons évoquées au cours de cette analyse bibliographique, l'attention particulière que nous portons sur l'approche de segmentation par fusions nous amène à présenter plus en détail les principales procédures relevant de cette technique. Leur étude commence par l'illustration des principales possibilités qu'offre la littérature pour définir les différentes étapes qui la composent, ce qui permet, ensuite, de dresser une liste des avantages et inconvénients des différentes stratégies existantes.

II SEGMENTATION PAR EXTRACTION DES REGIONS HOMOGENES.

II-1 Principes fondamentaux.

La figure IV-1 schématise le cheminement commun suivi par chacune des trois approches par extraction des régions homogènes.

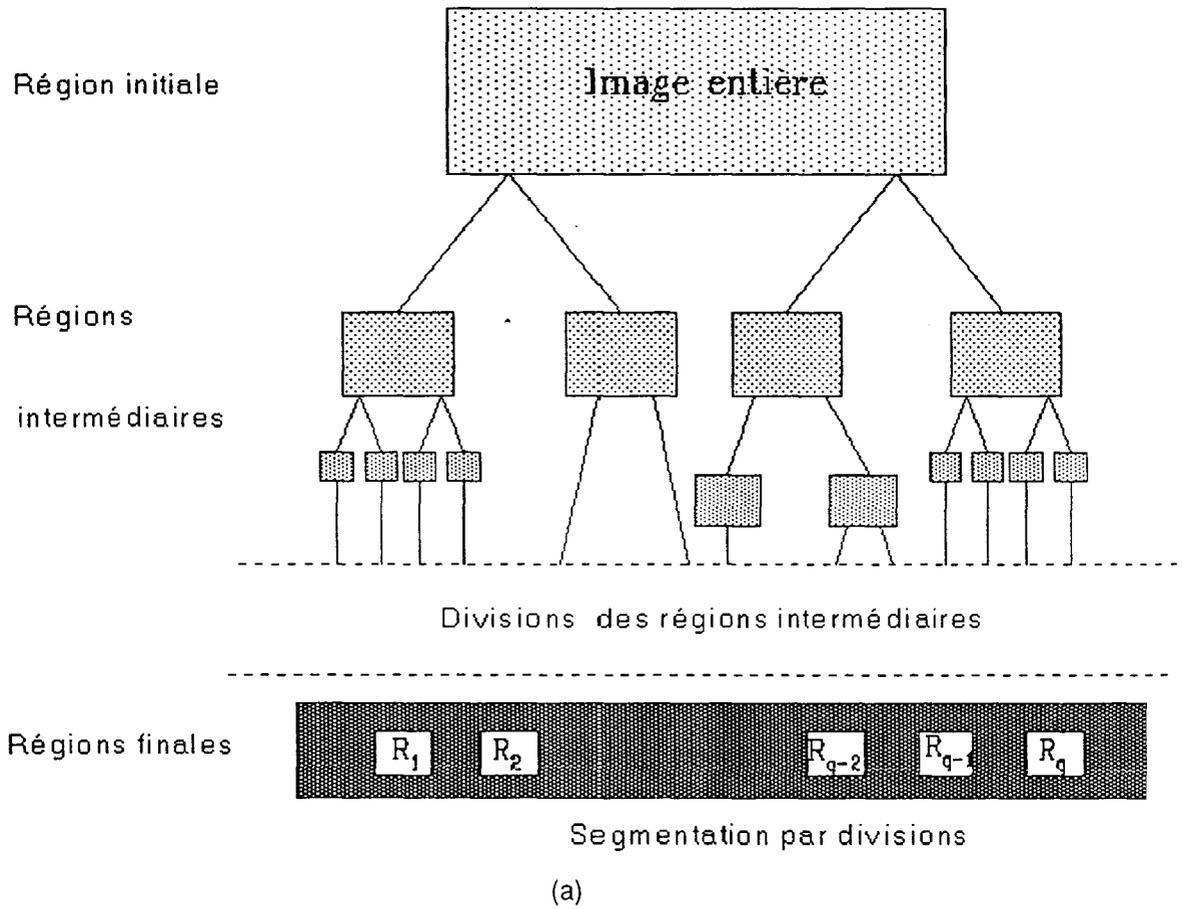


Fig. IV-1 : Les différentes procédures par extraction des régions homogènes.

a - Principe des approches de segmentation par divisions successives.

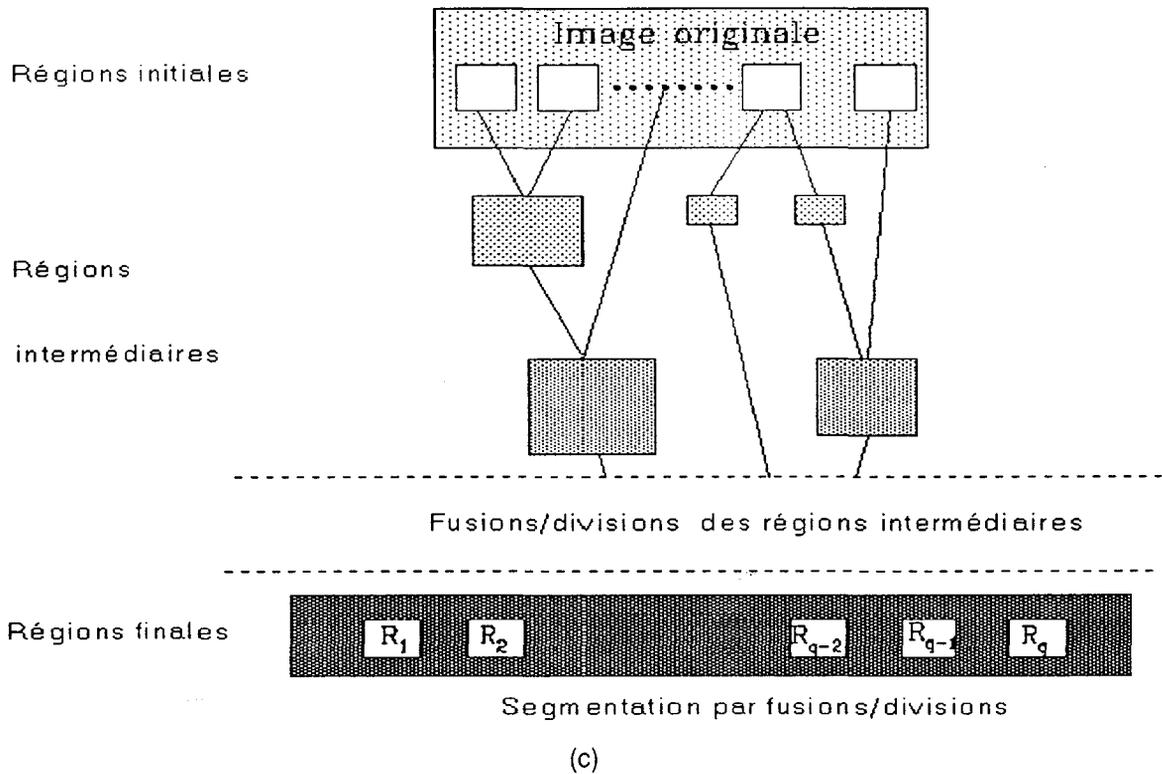
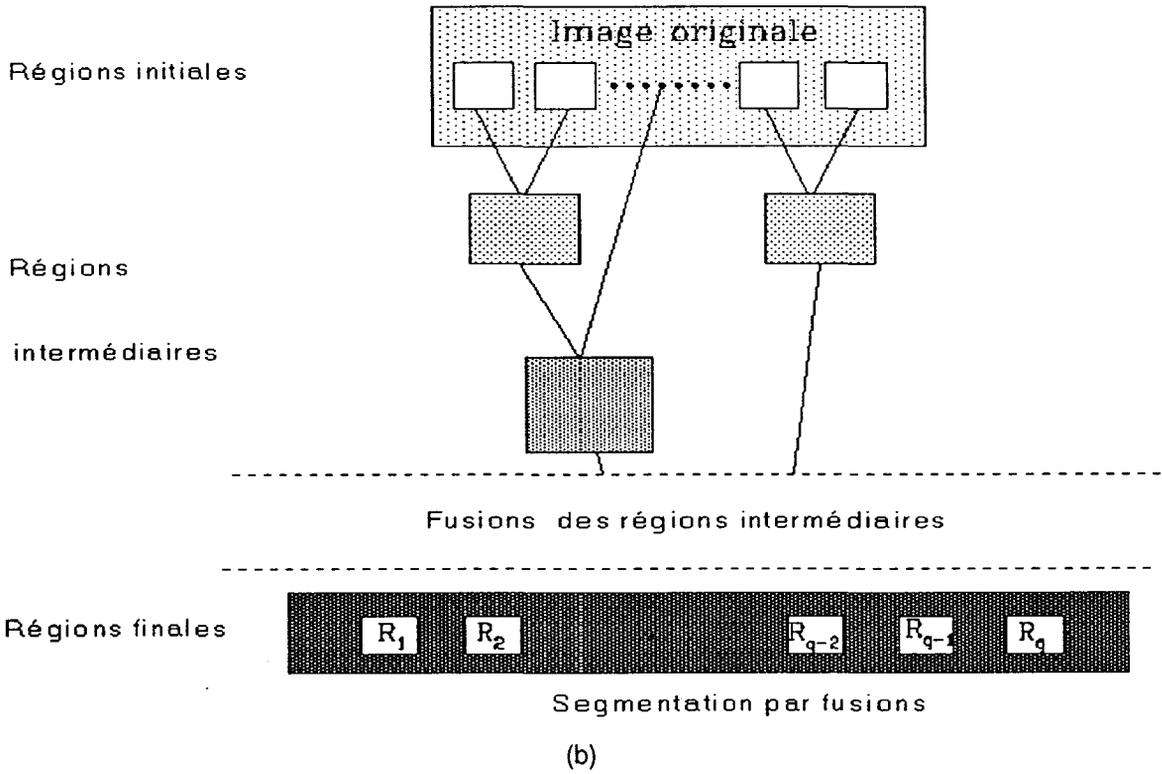


Fig. IV-1 : Les différentes procédures par extraction des régions homogènes.

b- Principe des approches de segmentation par fusions successives.

c- Principe des approches de segmentation par fusions et divisions successives.

Une idée commune aux trois approches de segmentation consiste d'abord à décomposer l'image en régions homogènes. Plusieurs caractéristiques, telles que le niveau de gris, la couleur ou tout autre attribut discriminant, sont ensuite relevées sur les points de chacune des régions initiales ainsi constituées. Ces caractéristiques relevées sont ensuite utilisées pour mesurer, au sens d'un critère prédéfini, l'homogénéité de chacune de ces régions. L'idée sous-jacente aux approches de segmentation par divisions successives consiste alors à construire les régions finales par divisions successives de l'image en régions de plus en plus petites, autant de fois que nécessaire jusqu'à ce que le critère d'homogénéité défini soit satisfait à l'intérieur de chacune des régions ainsi définies [Wu-82]. Les approches de segmentation par fusions successives partent, quant à elles, d'une partition initiale de l'image puis fusionnent successivement les régions en une seule région où leurs propriétés d'homogénéité sont conservées [Zuc-76]. Le processus par fusion s'arrête lorsque le critère d'homogénéité n'est plus vérifié sur aucune des régions issues d'un regroupement de plusieurs régions. Les méthodes par divisions et fusions successives combinent les deux approches précédentes. Ces méthodes commencent généralement à partir d'une partition initiale arbitraire de l'image en régions puis, à chaque étape, les régions sont soit divisées si elles ne sont pas homogènes, soit fusionnées si elles le sont [Hor-74].

II-2 Avantages et inconvénients.

II-2-1 Segmentation par divisions successives.

En prenant comme unique région initiale l'image entière, sa décomposition successive en régions se réalise généralement par divisions des régions intermédiaires reconnues non homogènes, au sens d'un certain critère, en plus petites régions de formes rectangulaires [Pav-77]. Ce type courant de décomposition constitue l'un des points faibles de cette approche, car le résultat obtenu fait apparaître des régions finales délimitées par des lignes brisées, constituées de segments de droite perpendiculaires aux axes de l'image, qui n'épousent pas forcément les frontières réelles des régions homogènes (fig. IV-2).

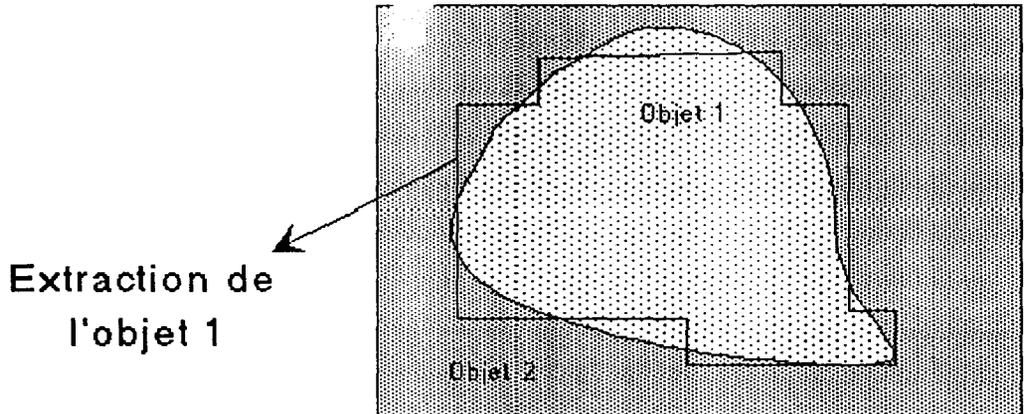


Fig. IV-2 : Illustration du premier type de défauts.

Il est également courant de constater qu'une même région homogène peut se trouver décomposée en plusieurs régions finales alors qu'elle aurait du conserver sa forme d'origine [Kli-75]. Ce défaut résulte du fait que de légères variations d'homogénéité peuvent être parfois perçues à l'issue de l'application du critère d'homogénéité (fig. IV-3). Ce type de comportement de l'algorithme se manifeste en particulier aux voisinages immédiats des frontières des régions homogènes où se localisent un ensemble de mosaïques constitué de régions de petites surfaces.

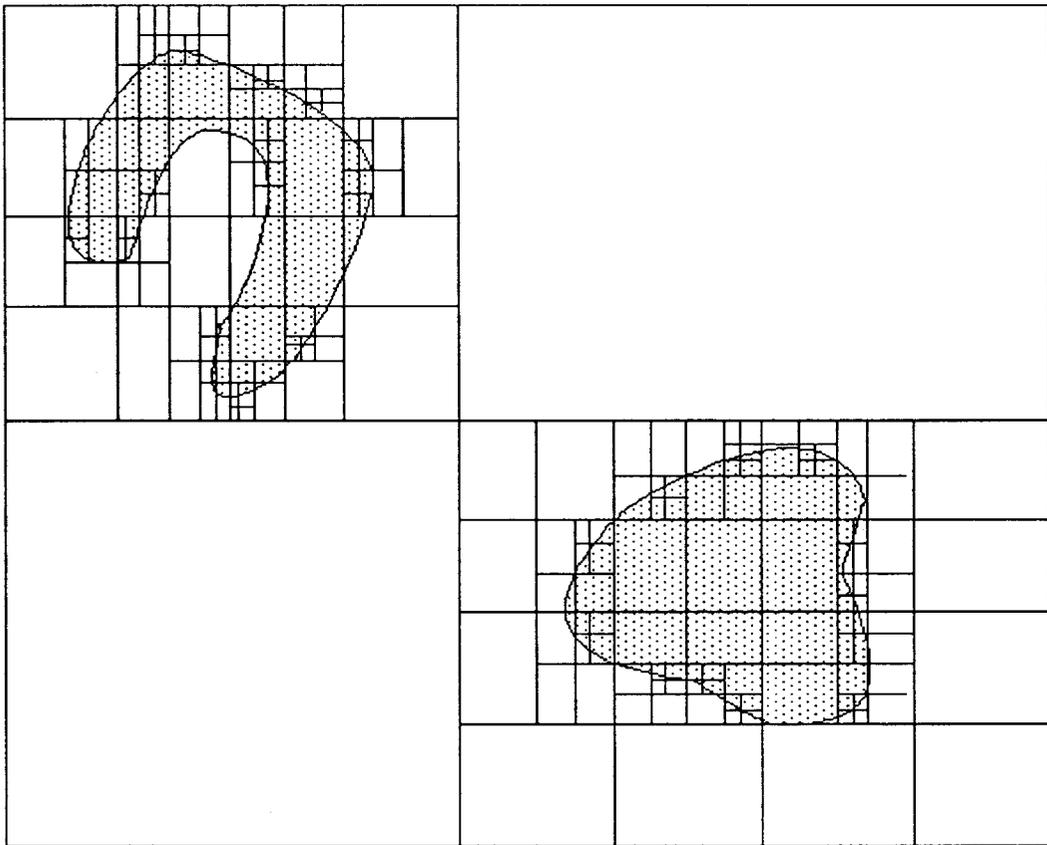


Fig. IV-3 : Illustration du second type courant de défauts.

Cette décomposition de l'image en petites régions offre cependant la possibilité d'analyser uniquement les régions de petite taille, riches en détails, au détriment des régions de plus grande taille. Généralement localisées au niveau du fond, ces dernières sont à l'inverse dépourvues d'intérêt. Cette stratégie d'analyse limitée à quelques régions est surtout intéressante pour des images comme les images biomédicales, pour lesquelles le fond couvre la quasi-totalité de la surface [Kli-78]. Le contenu intéressant de telles images, constitué par exemple de cellules, représente par contre la partie sur laquelle doit porter l'analyse (fig. IV-4).

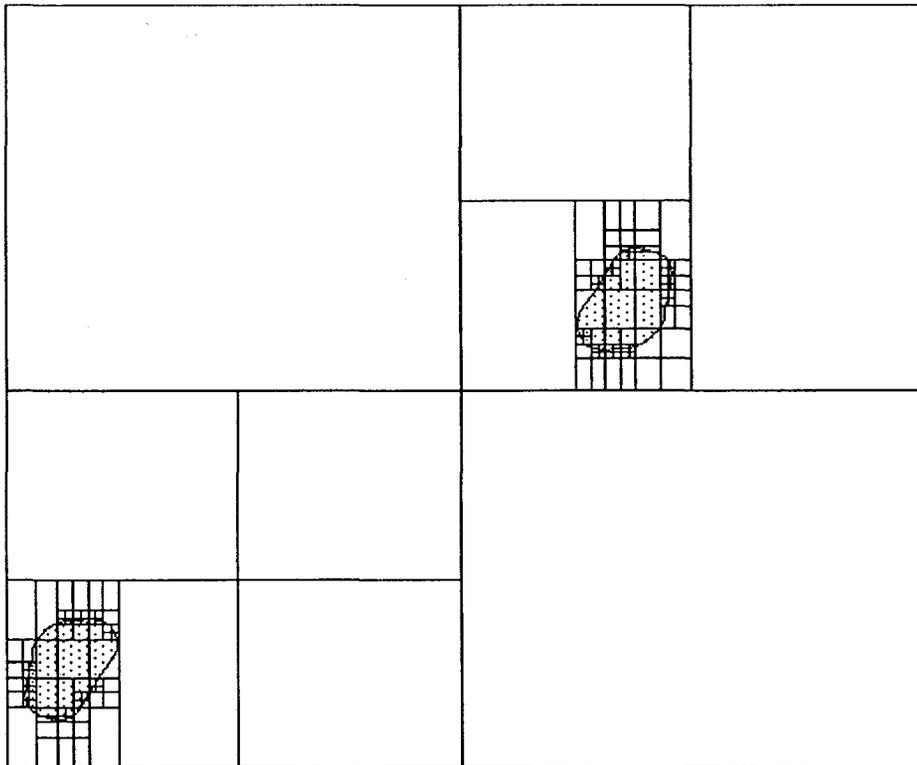


Fig. IV-4 : Illustration de la stratégie d'analyse restrictive d'une image.

Le risque d'altération de la qualité des résultats, dont l'origine provient des deux principaux types de défauts évoqués précédemment, se trouve trop élevé pour envisager la segmentation d'une image selon une telle procédure. En général, on préfère à ces méthodes par divisions successives celles qui procèdent par fusions successives, ou encore par fusions et divisions successives.

II-2-2 Segmentation par fusions successives.

Les méthodes de segmentation par fusions partent généralement d'une partition assez fine de l'image (les régions initiales peuvent être de surfaces 8x8, 4x4, 2x2 ou même n'être parfois constituées que d'un seul point), puis fusionnent successivement les régions jusqu'à ce que soit obtenue une partition finale de l'image en régions non fusionnables.

En général, bien que la décomposition finale de l'image soit de qualité meilleure que celle obtenue avec une segmentation par divisions, le résultat se trouve fortement lié à la nature séquentielle des fusions des régions. Le résultat de la segmentation

dépend, en effet, souvent de l'ordre dans lequel les régions sont examinées en vue d'éventuels fusionnements.

Une fusion préférentielle de certaines régions candidates au fusionnement peut pallier cet inconvénient en ne prenant, à chaque étape, que les régions qui répondent le plus favorablement à un critère de fusion [Mon-88]. Une autre alternative consiste à définir un certain nombre de petites régions initiales, appelées " noyaux ", et à n'appliquer la fusion que sur ces noyaux [Jol-87]. L'agrandissement mutuel de ces noyaux favorise une délimitation significative des régions obtenues. Dans ce cas particulier, il convient d'employer l'expression plus appropriée "expansion des noyaux" plutôt que celle de "fusionnement des noyaux". Nous reviendrons sur ce point ultérieurement. Plusieurs algorithmes sont étudiés dans la suite.

II-2-3 Segmentation par fusions et divisions successives.

Les méthodes alliant le principe de divisions et de fusions successives combinent les deux approches précédentes afin de tirer parti de leurs avantages qui sont complémentaires. Le processus démarre, comme pour les deux approches précédentes, d'une partition initiale de l'image. Un processus itératif par fusions et divisions est ensuite mis en oeuvre. A chacune de ses étapes, certaines régions présentes sont soit divisées si elles ne sont pas homogènes, soit fusionnées si, à l'inverse, elles sont similaires au sens d'un critère de fusion qui est, en général, différent du critère de division.

L'algorithme proposé par Horowitz et Palvidis est l'un des plus connus [Hor-74]. Il repose sur une approximation des fonctions luminances des régions initiales par des fonctions polynomiales. Les régions adjacentes modélisées par des fonctions semblables sont fusionnées entre-elles. A l'inverse, si l'erreur entre la fonction luminance d'une région et son modèle dépasse un certain seuil de tolérance, la région considérée est divisée en quatre plus petites régions. Une fois toutes les régions analysées, les fonctions luminances des nouvelles régions créées sont à leur tour modélisées. Cet algorithme par fusions et divisions successives est itéré jusqu'à stabilisation de la décomposition de l'image.

L'expérience montre que l'obtention de petites régions, localisées au niveau des contours de l'image, pose de sérieux problèmes sur la qualité des résultats finaux. Si

les contours de l'image sont peu prononcés, ces régions vont, en effet, avoir tendance à se fusionner avec leurs voisines, de surfaces plus grandes. Ce phénomène crée des liaisons entre les régions de type différents identifiées dans l'image.

Certains auteurs tentent de limiter ces effets en utilisant des heuristiques faisant appel à l'intensité du gradient au niveau des points des contours de l'image [Mon-87]. Toutefois, leur mise en oeuvre lourde ne favorise par leur application courante. Cette raison justifie notre préférence pour les méthodes de segmentation par fusions. La définition des régions initiales, ainsi que le fusionnement des régions initiales et intermédiaires, sont les deux étapes essentielles de ces procédures. Nous allons maintenant les étudier plus en détail.

III SEGMENTATION PAR FUSIONS SUCCESSIVES.

III-1 Définition des régions initiales.

III-I-1 Recherche des facettes.

Une modélisation en "facettes" de l'image consiste à rechercher des ensembles de points, de tailles maximales, tels que leurs niveaux de gris peuvent être approchés, au sens des moindres carrés, par une même fonction polynomiale. Les ensembles de points-image ainsi constitués, appelés facettes, constituent les régions initiales de l'image [Har-81, Pon-84].

De manière plus explicite, on suppose que l'image que l'on désire segmenter est décomposée en F facettes $F(1), \dots, F(f), \dots, F(F)$. Dans le cas idéal, les niveaux de gris $g(P_n(x,y))$ des points $P_n(x,y)$ d'une même facette $F(f)$ s'écrivent sous la forme :

$$g(P_n(x,y)) = \sum_{i=0}^d \sum_{j=0}^i a_{ij}(f) \cdot x^i \cdot y^{i-j}$$

où les $a_{ij}(f)$ sont les coefficients du modèle polynomial de degré d de la facette $F(f)$.

En réalité, les niveaux de gris $g(P_n)$ des points d'une même facette $F(f)$ ne vérifient pas avec exactitude l'équation du modèle polynomial mais s'en approchent avec une certaine marge d'erreurs. De ce fait, il est conseillé, avant toute recherche des

facettes dans l'image, de remplacer le niveau de gris de chacun des points de l'image par un niveau proche de ceux de son voisinage immédiat.

Pour cela, un moyen simple consiste à centrer sur chacun des points de l'image une fenêtre F_e de dimension appropriée [Ton-77, Pon-84]. La luminance des points-image sur lesquels la fenêtre a été ajustée est ensuite modélisée par une fonction polynomiale. La valeur estimée du niveau de gris au point central de chaque fenêtre F_e remplace, dans l'image d'origine, le niveau de gris réel $g(P_n(x,y))$ du point $P_n(x,y)$ se trouvant à la même position. L'itération de cette procédure se poursuit en prenant comme nouvelle image celle résultant de l'itération précédente. La convergence du processus a été établie dans [Har-81].

A l'issue de cette procédure, les facettes sont les ensembles de points connexes dont les niveaux de gris proviennent d'une même fonction polynomiale. Bien que la mise en oeuvre de cette procédure soit simple, elle se heurte cependant à quelques écueils.

Si l'estimation des niveaux de gris des points de la frontière de deux régions de types différents se confond avec celle des points d'un autre type, différencier ces derniers de ceux des deux premiers types s'avère impossible.

La taille de la fenêtre F_e , définissant le voisinage de chaque point-image, doit être choisie de manière adéquate afin que les contours réels des régions soient conservés, ainsi que les plus petits détails significatifs de l'image. Dans la pratique, son ajustement est délicat. En effet, si la dimension de la fenêtre est trop petite, les pics assimilés au bruit de l'image seront pris en compte dans le processus de modélisation au même titre que les autres points. A l'inverse, une taille trop grande aura pour effet de lisser les contours des régions.

En conclusion, bien qu'il soit possible d'étendre son champ d'application aux images de nature complexe [Pon-84], la construction des régions initiales par recherche des facettes ne peut conduire à des résultats significatifs que si les régions homogènes présentent des formes relativement simples.

Une alternative, dont les propriétés sont plus attrayantes, va maintenant être présentée.

III-1-2 Extraction des noyaux de l'image.

Les points-image présentant des occurrences en niveau de gris élevées dans l'image, constituent de bons représentants des classes C_q associées aux différents types de régions R_q . Jolion recommande de les utiliser pour identifier les régions initiales de l'image [Jol-87].

Pour ce faire, l'histogramme des niveaux de gris de l'image est décomposé en distributions normales. Les points associés à chaque distribution sont répartis entre deux classes. La première, appelée la classe sûre, est composée de points ayant de fortes occurrences dans la distribution normale à laquelle ils sont associés. La seconde, nommée la classe résiduelle, est constituée des autres points de plus faibles occurrences que les points assignés dans la classe sûre. Les ensembles de points connexes dans l'image, appartenant aux classes sûres de l'histogramme, constituent les noyaux de l'image. Chaque noyau identifié correspond à une région initiale de l'image.

Bien que cette approche ait été implantée avec succès pour le traitement d'images issues de la microscopie électronique [Jol-86], la qualité du résultat dépend beaucoup des noyaux initiaux, c'est à dire des valeurs des seuils utilisées pour décomposer l'histogramme. Pour remédier à ce problème, plusieurs ajustements de ces seuils sont possibles. Pour une même image, il existe alors autant de décompositions initiales de l'image que de possibilités de choisir ces seuils.

Pour chaque possibilité, les points assignés aux classes résiduelles sont affectés, selon une procédure de grossissement développée ultérieurement, aux noyaux qui leurs sont les plus proches dans l'image. Cela conduit, pour une même image, à autant d'images segmentées que de décompositions initiales de l'image.

Les probabilités a priori, en chaque point-image, d'appartenance aux classes constituées C_q , sont ensuite estimées. Pour cela, le nombre de fois que chaque point a été affecté à une même classe est évalué sur l'ensemble des images segmentées. Cette estimation a priori sert ensuite à classer chaque point à la classe pour laquelle sa

probabilité d'appartenance est la plus élevée. Chaque classe C_q ainsi constituée regroupe les points-image des régions homogène de type R_q .

Cette procédure nous paraît plus attrayante que celle utilisant une modélisation de l'image en facettes, du fait des caractéristiques que possèdent les régions initiales qui peuvent ainsi être de formes quelconques avec des contours dont l'aspect est plus régulier. Toutefois, sa mise en oeuvre nous semble trop coûteuse en temps de calcul.

Nous allons maintenant étudier d'autres approches plus simples pour constituer les régions initiales de l'image.

III-1-3 Recherche des ensembles de points de propriétés semblables.

L'approche la plus simple consiste à assimiler chaque point-image à une région initiale. Cette approche ne nécessite aucun calcul. Mais, en revanche, la reconstruction des régions homogènes devient très laborieuse. Un très grand nombre de régions doivent être fusionnées avant d'obtenir la segmentation finale de l'image analysée.

Afin d'alléger cette procédure, on pourrait utiliser une division arbitraire en petites cellules au lieu de limiter une région à un seul point-image [Mue-68]. Chaque cellule constituerait une région initiale. On retombe malheureusement dans le cas d'une division d'aspect rectangulaire. Et, de plus, rien n'assure que chaque cellule renferme un ensemble de points-image provenant d'une même région, c'est à dire possédant des propriétés semblables.

Brice et Fennema proposent de diviser l'image en ensembles initiaux de points de même intensité [Bri-70]. Aucune valeur de seuil garantissant l'homogénéité d'une région n'est requise. Cette propriété s'avère intéressante car il est très difficile d'ajuster des paramètres de seuillage sans connaissance a priori sur le contenu de l'image. Cette méthode de définition des régions initiales semble donc, de ce point de vue, être plus intéressante que les précédentes.

Lorsque les régions initiales de l'image sont construites, il s'agit de définir la stratégie de fusion. Plusieurs alternatives sont proposées dans le paragraphe suivant.

III-2 Fusions successives des régions initiales et intermédiaires.

Deux aspects déterminants sur la qualité de la segmentation finale sont à souligner.

Le premier aspect réside dans l'utilisation ou non de seuils pour contrôler le fusionnement des régions de la procédure. Certains algorithmes de segmentation par fusions requièrent, en effet, par le biais d'un jeu de paramètres, un seuil d'homogénéité au delà duquel la fusion de deux régions est interdite. Or, il n'est pas facile de définir ce seuil lorsque rien n'est a priori connu sur l'image.

Le second aspect réside dans la manière de rechercher les régions initiales ou intermédiaires à fusionner. En effet, certains algorithmes, dits séquentiels, scrutent l'image dans un sens prédéfini et regroupent en une seule région le premier couple rencontré composé de deux régions adjacentes qui présentent des propriétés similaires. D'autres approches, dites hiérarchiques, retiennent le ou les fusionnements des couples de régions présentant des propriétés d'homogénéité les plus marquées. Cette façon de procéder est recommandée si on désire obtenir une segmentation finale de l'image indépendante de l'ordre de fusionnement.

III-2-1 Seuil de contrôle du fusionnement des régions.

Le succès de la procédure de fusionnement est souvent lié à la sélection d'un seuil approprié mettant en jeu un ou plusieurs paramètres de contrôle de fusion. Bien que ce seuil influence sensiblement la qualité de la segmentation finale de l'image, son utilisation peut cependant être avantageuse pour les diverses raisons évoquées dans la suite.

a) Expansion des noyaux de l'image.

Rappelons que l'histogramme des niveaux de gris de l'image analysée peut être décomposé en deux types de classes. Les points des classes sûres qui forment les noyaux de l'image et ceux des classes résiduelles.

Le principe itératif proposé par Jolion pour reconstruire les régions homogènes de l'image consiste à étendre uniformément tous les noyaux en leur assignant les points-

image, appartenant aux classes résiduelles associées aux distributions normales de l'histogramme, qui leur sont les plus proches. La notion de proximité, définie selon un concept de voisinage bien connu en traitement des images [Ros-70], est fonction d'un second paramètre dont la valeur agit sur la vitesse de croissance des noyaux. A l'issue de chaque itération, les noyaux sont ceux de l'étape précédente, augmentés des points qui leur ont été assignés. La procédure d'accroissement des noyaux s'arrête dès que tous les points de l'image ont été associés à l'un des noyaux présents. Chaque noyau formé représente une région homogène identifiée dans l'image. A la fin du processus, tous les points de l'image sont assignés à un noyau. On obtient autant de régions que de noyaux initiaux.

L'algorithme commence par analyser l'information lumineuse pour constituer les noyaux initiaux, puis analyse leurs relations spatiales afin de les faire croître. La qualité des résultats repose donc essentiellement sur l'étude préalable de l'intensité lumineuse des points. Ceci constitue le point faible de cette approche.

b) Fusion des facettes.

Pavlidis a montré que si F facettes sont utilisées pour modéliser la fonction luminance de l'image, alors P facettes, avec $P < F$, peuvent s'en approcher avec une erreur de modélisation bornée par une quantité μ [Pav-72].

En jouant sur la valeur de μ , l'image peut être décomposée en un nombre plus ou moins élevé de facettes. Le nombre de facettes ainsi que leurs tailles, et donc par conséquent le nombre de régions ainsi que leur étendue finale, sont fonctions de l'erreur de modélisation tolérée par le biais du paramètre μ .

En jouant sur la valeur de ce dernier paramètre, les détails de l'image seront préservés ou éliminés dans l'image segmentée I_s .

Cependant, il n'est pas toujours aisé de définir un seuil de contrôle de fusion lorsque l'on ne connaît rien a priori sur le contenu de l'image. Des procédures par fusions non supervisées ont donc été élaborées afin de fournir une segmentation totalement indépendante de la nature de l'image analysée. Le travail de Robbe s'inscrit dans cette perspective [Rob-92].

c) Par analyse de la connexité des points.

Robbe définit une région de l'image comme un ensemble de points de niveaux de gris homogènes présentant de fortes liaisons spatiales. Il recherche dans l'image des ensembles constitués de points ayant, entre eux, une grande homogénéité de niveau de gris et de fortes propriétés de connexité. Il définit la notion de degré de connexité d'un ensemble afin d'évaluer le degré moyen de connexité des points le constituant. L'analyse arborescente de la pyramide des degrés de connexité associée à l'image analysée est une approche originale pour la recherche des ensembles dont les points présentent des liaisons spatiales maximales. A l'issue de l'analyse de cette pyramide, il existe autant d'ensembles de points que de régions identifiées dans l'image. Les performances de sa procédure sont intéressantes, d'autant plus qu'aucun paramètre de contrôle de fusionnement n'est exigé pour sa mise en oeuvre.

Le second aspect déterminant sur la qualité de la segmentation finale réside dans la manière de fusionner les régions initiales et intermédiaires. Pour ce faire, on dispose de deux modes différents de fusionnements dont les principales caractéristiques vont maintenant être présentées.

III-2-2 Ordre de fusionnement des régions.

a) Ordre séquentiel.

Le premier mode de fusion consiste à scruter séquentiellement l'image dans un sens prédéfini afin de regrouper en une seule région le premier couple rencontré composé de deux régions adjacentes présentant des propriétés similaires. Le principe de fusionnements proposé par Muerle et Allen [Mue-68] suit ce mode de fusionnement. L'image est divisée en cellules plus ou moins grandes (2x2, 4x4, 8x8 points-image). Une mesure statistique est ensuite relevée sur chaque cellule. Cette mesure peut être, par exemple, la moyenne des niveaux de gris des points-image de la cellule.

La première cellule (en haut et à gauche de l'image) est ensuite prise en compte. Si les mesures statistiques effectuées sur les cellules voisines de la cellule considérée sont similaires au sens d'un certain critère, ces cellules sont fusionnées en une même région. Après chaque fusion, la mesure effectuée sur la région ainsi constituée est

remise à jour.

Le processus est itéré jusqu'à ce que la région résultante ne puisse plus être fusionnée avec ses cellules adjacentes. Une nouvelle cellule, non fusionnée à la région définie précédemment, est ensuite prise en considération. Le même principe de fusionnement lui est appliqué. Une fois toutes les cellules étudiées, la segmentation de l'image est terminée.

Les problèmes apparaissent au niveau du sens de scrutation des cellules. Les résultats de la segmentation dépendent, en effet, non seulement de la quantité d'information apportée par chaque cellule, mais également de l'ordre dans lequel on fusionne les cellules. Rien ne dit qu'au terme de la procédure, les cellules sont fusionnées de manière optimale au sens du critère de fusion défini. Il se peut, en effet, qu'une ou plusieurs cellules soient regroupées dans une même région alors qu'il aurait mieux valu, pour des raisons de meilleure homogénéité, qu'elles soient fusionnées avec une autre région prise en compte par la suite.

b) Ordre hiérarchique.

Pour remédier à ce problème, l'algorithme proposé par Monga [Mon-88] consiste à utiliser une stratégie de regroupement plus performante que la précédente. Au lieu de regrouper les régions adjacentes dès que le critère de fusion est vérifié, il crée une hiérarchie de fusions en rangeant les couples de régions suivant les valeurs croissantes du critère. Il regroupe ensuite les couples de régions les plus homogènes au sens du critère de fusion. L'algorithme tire ses performances de cette stratégie de regroupement des régions.

IV CONCLUSION.

Les techniques de segmentation opérant par classification statistique des points de l'image ont, en commun, le défaut de ne pas tenir compte de l'information spatiale existante entre ces points-image. Or, cette information est de la toute première importance pour assurer à l'ensemble des points de chaque région homogène identifiée dans l'image une certaine cohésion spatiale. Combiner l'information statistique relevée sur les points-image avec l'information spatiale existante entre-eux, telle est la perspective des procédures par extraction de régions présentées dans ce chapitre.

Après avoir développé les principes généraux sur lesquels reposent les approches par extraction de régions, nous nous attachons plus particulièrement aux procédures opérant par fusions successives. Ces méthodes par fusions successives partent généralement d'une partition de l'image en régions initiales, puis fusionnent successivement ces régions jusqu'à obtention d'une partition finale de l'image en régions non fusionnables. Des problèmes apparaissent dans la définition des régions initiales et au niveau de l'ordre selon lequel les régions candidates à la fusion sont scrutées. Nous avons vu qu'il était préférable que les régions initiales aient des contours d'aspect non rectangulaire et que la fusion des régions soit réalisée de manière hiérarchique. C'est dans ce contexte que nous proposons, dans le chapitre suivant, une nouvelle procédure de segmentation par fusions successives.

**V- UNE NOUVELLE APPROCHE DE
SEGMENTATION DES IMAGES
PAR CROISSANCE HIERARCHIQUE
DES REGIONS -**

UNE NOUVELLE APPROCHE DE SEGMENTATION DES IMAGES PAR CROISSANCE HIERARCHIQUE.

I INTRODUCTION.

Bien que notre préférence se porte davantage sur les approches par fusions successives afin de pallier le manque d'information spatiale dans la détermination des seuils de segmentation, leur étude, dans le chapitre précédent, nous ont montré que, dans la plupart des approches par fusions successives classiques, les résultats obtenus dépendent étroitement de l'ordre dans lequel sont considérés les couples de régions à regrouper. La qualité des approches par fusions successives se trouve également altérée par l'aspect brisé des contours des régions finales issues d'un regroupement de plusieurs régions initiales de formes rectangulaires.

L'approche que nous proposons, dans ce chapitre, supprime ces deux défauts en définissant, d'une part, une hiérarchie de croissances des couples de régions adjacentes grâce à l'optimisation d'un critère de fusion et d'autre part définit chaque région initiale comme un ensemble de points, possédant dans l'image, des contours de forme non régulière. Cela confère donc aux contours des régions finales, issues du regroupement des régions initiales, la propriété de présenter des aspects non brisés.

II PRINCIPE DE LA SEGMENTATION DES IMAGES PAR CROISSANCE HIERARCHIQUE.

Notre approche s'articule autour des trois phases suivantes :

- 1- Constitution des régions initiales.
- 2- Accroissement des régions initiales/intermédiaires.
- 3- Arrêt de l'accroissement des régions.

Notre procédure figure dans la catégorie particulière des approches par fusions

successives qui procèdent, pour identifier les régions homogènes de l'image, à un accroissement progressif des régions initialement constituées. Cet accroissement se réalise selon une procédure d'affectation itérative des points-image aux classes de points associées aux régions initiales. Le principe de notre approche consiste à rassembler le plus grand nombre de points présentant de fortes liaisons spatiales, dans une classe de points représentative d'un type de régions de l'image. Au terme de la procédure, deux classes de points sont identifiées. La première rassemble les points appartenant au fond de l'image tandis que la seconde classe rassemble les points appartenant aux objets présents dans l'image.

Avant de présenter le déroulement de l'algorithme, il convient de définir deux notions : l'homogénéité en niveau de gris d'un ensemble de points ainsi que le degré de connexité entre deux ensembles de points.

II-1 Définition de l'homogénéité en niveau de gris d'un ensemble de points-image.

Considérons un ensemble E_1 de points-image sur lequel on veut mesurer l'homogénéité en niveau de gris. De nombreuses approches statistiques sont à notre disposition pour quantifier cette homogénéité. A titre d'exemple, la variance des niveaux de gris des points de cet ensemble peut être une mesure efficace pour mesurer cette homogénéité.

Bien qu'ils existent de nombreuses approches statistiques permettant d'évaluer l'homogénéité en niveau de gris d'un ensemble de points, nous retenons une approche très simple qui consiste à considérer un ensemble E_1 comme un ensemble homogène si les niveaux de gris de ses points sont contenus dans une plage continue de niveau de gris $[ndg_1, \dots, ndg_2]$ définie par les deux valeurs extrêmes ndg_1 et ndg_2 des niveaux de gris des points de cet ensemble.

II-2 Définition du degré de connexité entre deux ensembles homogènes.

Plusieurs nouvelles notions doivent être définies pour quantifier les liens de connexité qui existent entre deux ensembles :

Soient deux ensembles de points E_1 et E_2 homogènes dans le sens défini

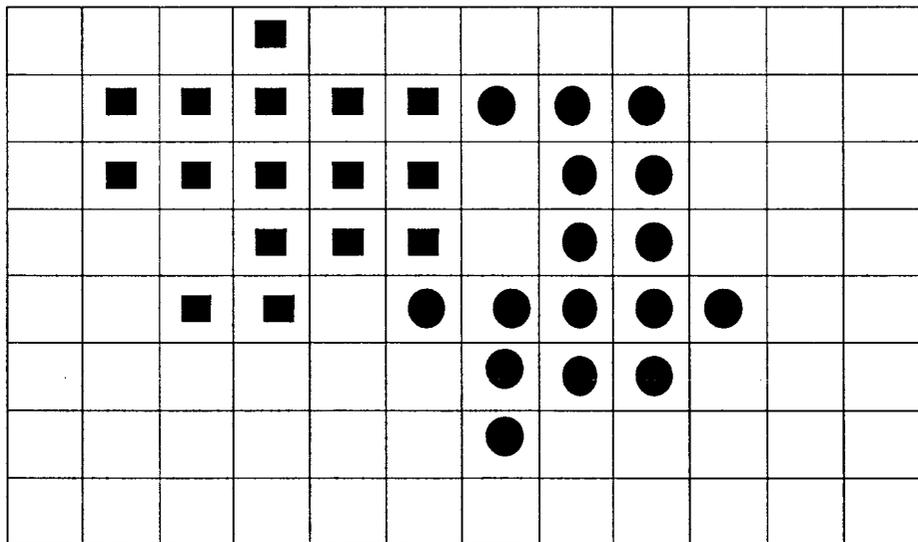
précédemment. On suppose, de plus, que les plages respectives des niveaux de gris de leurs points ne se recouvrent pas. Dans ce cas, E_1 et E_2 sont qualifiés d'ensembles homogènes et distincts. Sous cette hypothèse, la question que l'on se pose est la suivante :

Les points de E_1 et de E_2 sont-ils suffisamment proches dans l'image pour pouvoir être assignés à une même classe associée à un type de régions homogènes.

Deux cas de figure se présentent :

- la figure V-1-a illustre le cas où les points de E_1 et de E_2 sont trop espacés dans l'image pour pouvoir être assignés à une même classe.

- L'exemple de la figure V-1-b est une illustration du second cas de figure. Les points de E_1 et de E_2 présentent de fortes liaisons spatiales. Il est fort probable que les points qui les constituent forment une même région homogène de l'image.



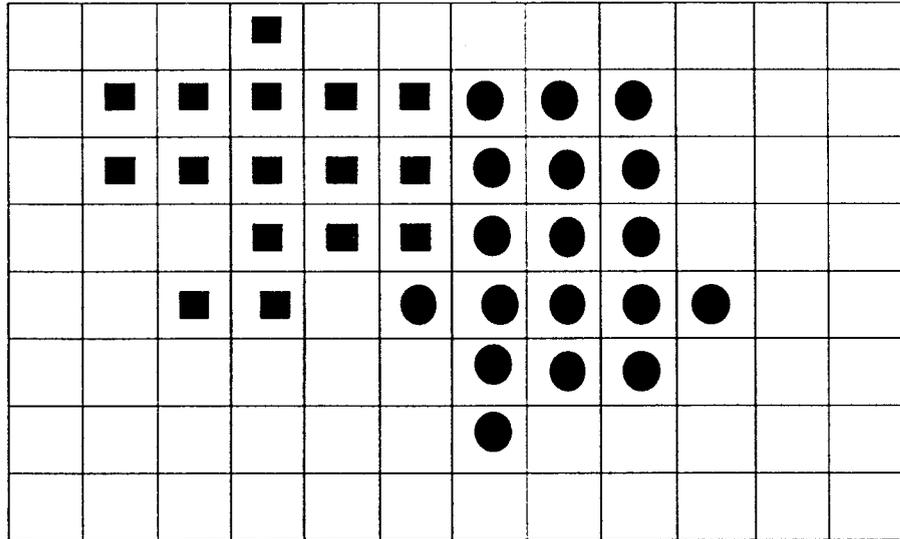
■ Points-image de l'ensemble E_1

● Points-image de l'ensemble E_2

(a)

Fig. V-1 : Représentation de deux ensembles de points dans une image.

a- Faible liaison spatiale entre leurs points.



- Points-image de l'ensemble E_1
- Points-image de l'ensemble E_2

(b)

Fig. V-1 : Représentation de deux ensembles de points dans une image.

b- Forte liaison spatiale entre leurs points.

Il s'agit maintenant de quantifier les liaisons spatiales existantes entre les points de E_2 , notés P_2 , et ceux de E_1 , notés P_1 , afin de décider si leurs points peuvent être assignés à une classe associée à un même type de région homogène où doivent être assignés à deux classes associées à deux types différents de régions.

Pour cela, il suffit de dénombrer le nombre de voisins P_2 appartenant à E_2 dans le voisinage immédiat de chaque point P_1 de E_1 . Pour des raisons d'isotropie, le voisinage, choisi carré de taille 3×3 , est centré sur chaque point analysé P_1 de E_1 . Les v voisins P_2 appartenant à E_2 situés dans le voisinage immédiat centré sur un point P_1 de E_1 sont dits v -connexes à ce point. La figure V-2 représente quelques configurations possibles qui peuvent être rencontrées.

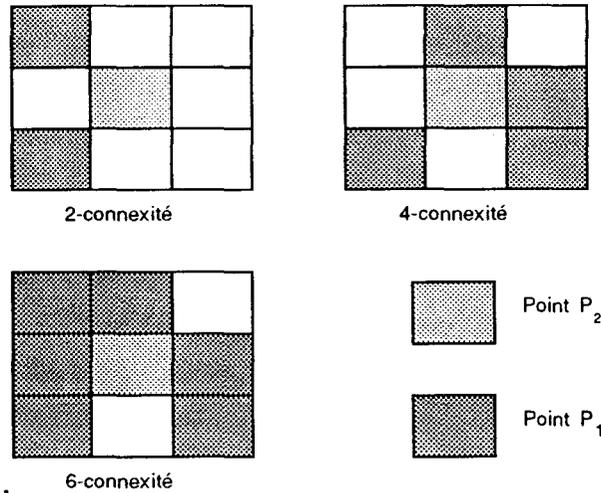


Fig. V-2 : Différentes configurations possibles de voisinage.

La somme des v -connexités des points P_2 de E_2 par rapport à l'ensemble des points P_1 de E_1 représente la connexité spatiale existante entre les deux ensembles homogènes E_1 et E_2 . Cette connexité, notée $C[E_2/E_1]$, est ainsi définie par :

$$C[E_2 / E_1] = \sum_{P_2 \in C_2} v\text{-connexité} \quad \text{avec } v=1,2,\dots,8$$

Il est à noter que la 0-connexité n'est pas prise en considération dans le calcul afin que $C[E_2/E_1]$ quantifie bien la connexité des points appartenant à la frontière commune entre E_1 et E_2 .

En effet, les points de connexité nulle sont ceux qui n'ont comme voisins immédiats que des points appartenant au même ensemble que le point sur lequel la mesure de la v -connexité est mesurée. Ces points appartiennent au coeur des ensembles E_1 et E_2 et non à leurs frontières communes. Ils ne sont pas pris en compte dans le calcul de $C[E_2/E_1]$ afin que cette mesure soit indépendante de la différence de taille des deux ensembles E_1 et E_2 analysés (fig. V-3).

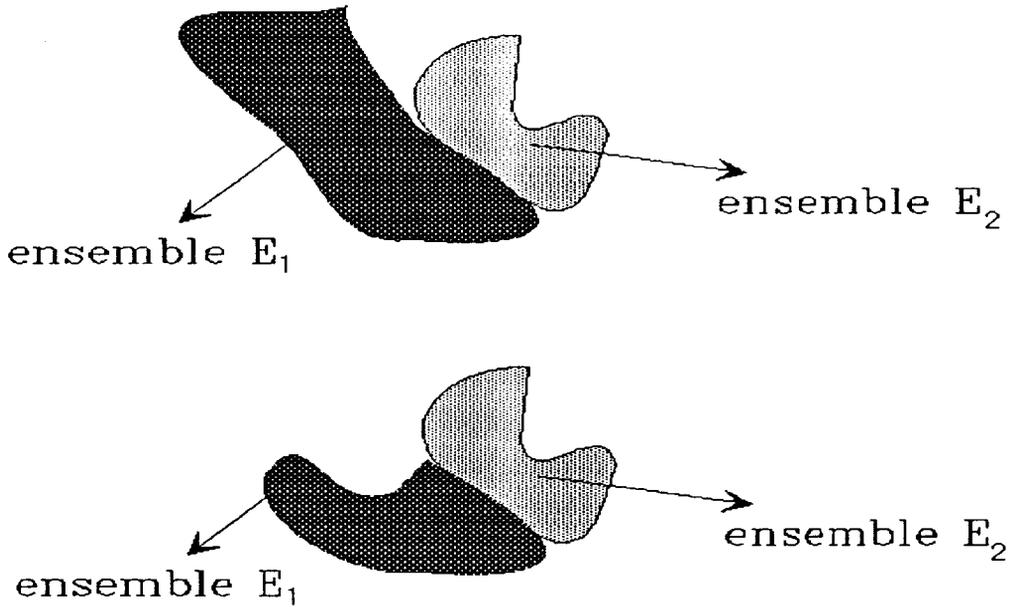


Fig. V-3 : Deux cas de figure pour lesquels la connectivité $C[E_2/E_1]$ est la même.

Afin de rendre le concept de connectivité des deux ensembles également indépendant de la longueur de leurs frontières communes, on est amené à diviser la quantité $C[C_2/C_1]$ par le nombre de points $NB[P_1]$ de E_1 ayant dans leurs voisinages au moins un point P_2 appartenant à C_2 . La quantité résultante définit ce qu'on appellera le degré de connectivité moyen des points frontières de E_2 avec ceux de E_1 .

$$DC[E_2 / E_1] = \frac{1}{NB[P_1]} \sum_{P_2 \in C_2} v\text{-connectivité.}$$

Cette quantité $DC[C_2/C_1]$ fournit un bon indice de fusion car plus sa valeur est élevée, plus les points de ces deux ensembles E_1 et E_2 ont de fortes chances d'appartenir à une même région homogène du fait de leurs fortes liaisons connexes existantes dans l'image.

II-3 Présentation de la méthode par analyse de la connexité.

II-3-1 Constitution des régions initiales.

La décomposition de l'image en régions initiales doit se réaliser de telle manière que chaque région constituée vérifie la propriété d'homogénéité telle que nous l'avons établie. Si on définit une région initiale comme un ensemble de points $E(g_n)$ de même niveau de gris g_n , l'homogénéité est vérifiée sur chaque ensemble de points. Chacun d'eux est, en effet, constitué de points dont la plage des niveaux de gris se réduit à un unique niveau de gris.

Pour une image I composée de points de niveau de gris g_n pouvant présenter $m+1$ niveaux de gris g_0, g_1, \dots, g_m , la décomposition donnera $m+1$ régions initiales R_0, R_1, \dots, R_m . A ces régions sont associés $m+1$ ensembles élémentaires $E(g_0), E(g_1), \dots, E(g_m)$.

Les régions finales obtenues, issues du fusionnement des régions initiales, auront des contours de forme non rectangulaire puisque les régions initiales ainsi constituées sont de formes quelconques.

II-3-2 Procédure de fusionnement.

La mise en oeuvre de la procédure de fusionnement doit permettre de proche en proche d'obtenir des régions homogènes de tailles de plus en plus grandes. Au terme de la procédure, l'ensemble des régions finales représente l'image originale segmentée.

Le principe de notre procédure itérative par fusions consiste à regrouper à chaque étape les deux ensembles de points les plus connexes au sens du critère établi précédemment. Cette manière de procéder évite ainsi que les résultats soient tributaires de l'ordre avec lequel sont étudiés les couples d'ensembles en vue d'un éventuel regroupement. Notre procédure par fusions s'inscrit donc dans le cadre des procédures de segmentation par fusions hiérarchiques.

L'analyse exhaustive des $(m+1)!$ couples d'ensembles susceptibles d'être fusionnés n'est pas une procédure envisageable du fait du calcul important qu'exigerait

la mise en oeuvre de cette procédure. Pour simplifier la recherche du couple d'ensembles à fusionner, nous émettons l'hypothèse que le premier ensemble $E(g_0)$, extrait de la liste des ensembles $E(g_0), \dots, E(g_m)$ ordonnés selon les niveaux de gris g_0, \dots, g_m croissants de l'image, rassemble les points-image appartenant au premier type R_1 de régions à identifier tandis que le dernier ensemble $E(g_m)$ de la liste est constitué des points-image appartenant au second type R_2 de régions. Cette hypothèse est basée sur le principe même de la procédure de seuillage global qui fait appel à un seuil unique tel que sa valeur T délimite les deux plages de niveau de gris $[g_0, \dots, T]$ et $[T+1, \dots, g_m]$ associées aux deux types R_1 et R_2 de régions. De ce fait, les ensembles de points $E(g_0)$ et $E(g_m)$ appartiennent a fortiori aux deux types respectifs R_1 et R_2 de régions homogènes. $E(g_0)$ et $E(g_m)$ sont dits les représentants des deux classes C_1 et C_2 de points-image associées aux deux types de régions.

A ce stade de l'analyse, il suffit maintenant de calculer les degrés de connexité des autres ensembles $E(g_1), \dots, E(g_{m-1})$ par rapport aux deux ensembles $E(g_0)$ et $E(g_m)$.

Parmi l'ensemble des degrés de connexité calculés par rapport à chacun des deux ensembles $E(g_0)$ et $E(g_m)$, il existe un degré de connexité plus élevé que les autres. Soit $DC(g_p, g_n)$ ce degré avec $p=0$ ou $p=m$.

Si $p = 0$, alors l'ensemble des points représentatifs de la classe C_1 du premier type de régions va être, à l'étape suivante, constitué des points appartenant à la plage continue $[g_0, \dots, g_n]$ tandis que $E(g_m)$ reste représentatif de la classe C_2 des régions de type R_2 (fig. V-4).



Fig. V-4 : Accroissement de la classe C_1 .

Comme l'indique cet exemple, les points dont les niveaux de gris sont compris entre g_0 et g_n sont aussi assignés à cette classe.

Si $p = m$, alors l'ensemble des points représentatifs de la classe C_2 du second type de régions va être, à l'étape suivante, constitué des points appartenant à la plage continue $[g_n, \dots, g_m]$ tandis que $E(g_m)$ reste représentatif de la classe C_1 des régions de type R_1 (fig. V-5).



Fig. V-5 : Accroissement de la classe C_2 .

Les points dont les niveaux de gris sont compris entre g_n et g_m sont aussi assignés à cette classe.

II-3-3 Arrêt de fusionnement.

L'itération se poursuit jusqu'à ce que tous les points soient assignés à l'une des deux classes C_1 ou C_2 associées aux deux types de régions. Le seuil utilisé dans la procédure de seuillage pour différencier les deux types de régions est choisi au niveau de gris maximal des points de la classe C_1 , c'est à dire au niveau minimal des points de la classe C_2 .

III APPLICATION DE LA PROCEDURE PAR FUSIONS.

La première image étudiée, de format 320x200, représente du tissu imprimé (fig. V-6). Les niveaux de gris des points de l'image sont compris dans la plage continue des niveaux $[14, \dots, 118]$. A l'étape initiale, la classe C_1 est constituée des points de niveau de gris 14 tandis que C_2 est constituée des points de niveau de gris 118.

Les deux images suivantes (fig. V-7-a et V-7-b) représentent le classement des points en trois classes au bout de la 40^{ème} et de la 47^{ème} itération, Les points de la classe C_1 y figurent en noir. Les points non encore assignés sont de couleur grise, tandis que la couleur blanche est attribuée aux points assignés à la classe C_2 . A la 60^{ème} itération, l'image segmentée résultante (fig. V-8) nous paraît satisfaisante car les régions identifiées épousent les contours des régions de l'image originale. On constate

également que le seuil trouvé se trouve au creux de la vallée des deux modes de l'histogramme (fig. V-9).

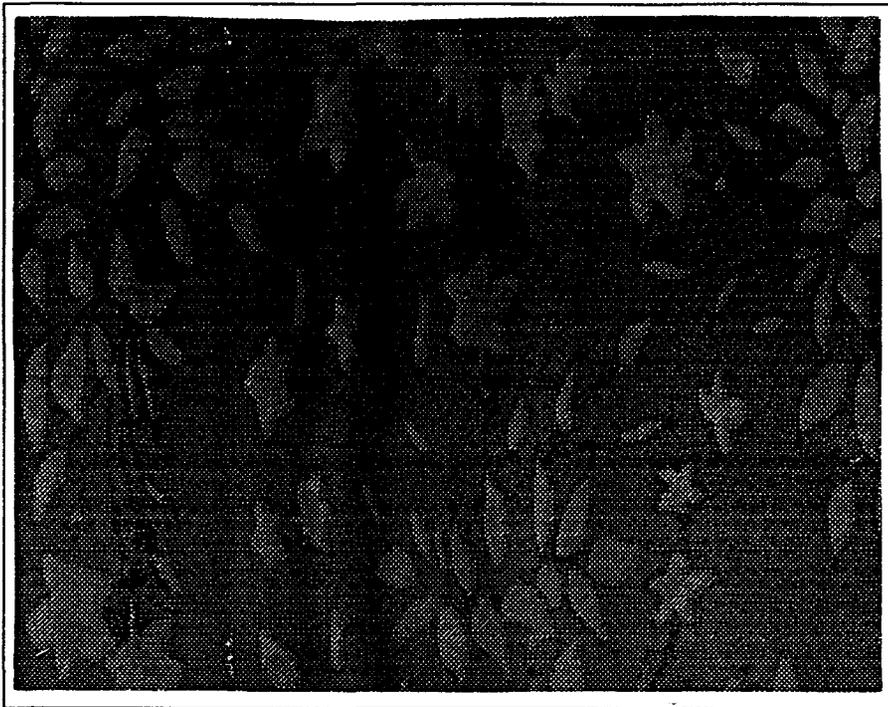
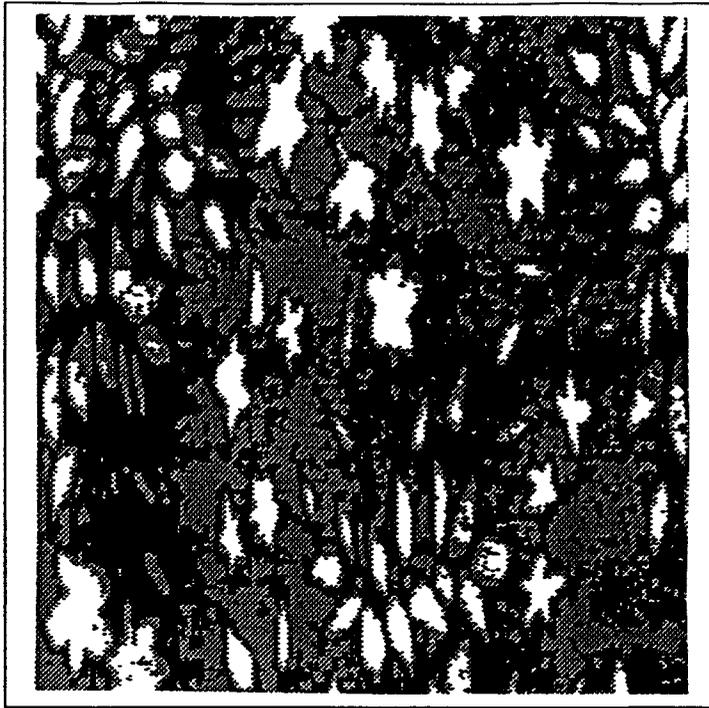
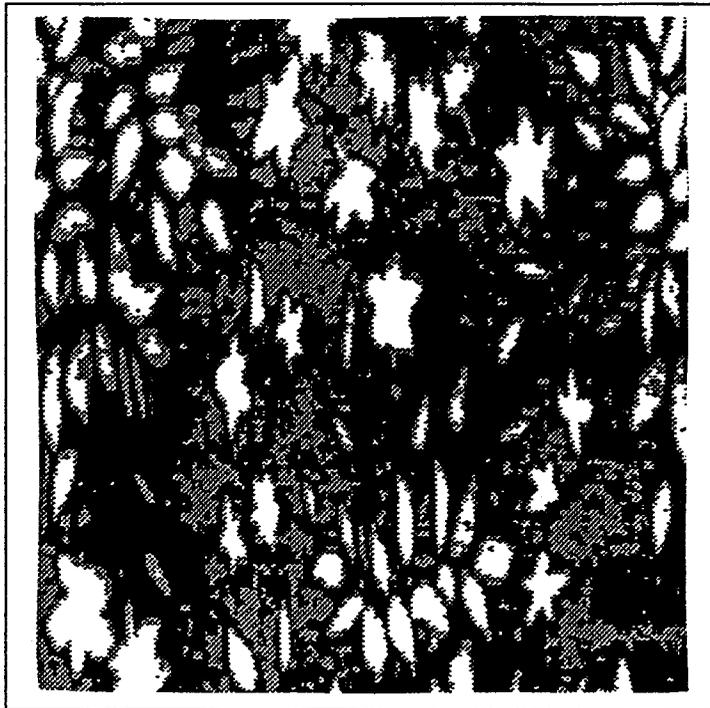


Fig. V-6 : Image originale.



(a)



(b)

Fig. V-7 : Classement des points.

a- Au bout de la 40^{ème} itération.

b- Au bout de la 47^{ème} itération.



Fig. V-8 : Image binarisée.

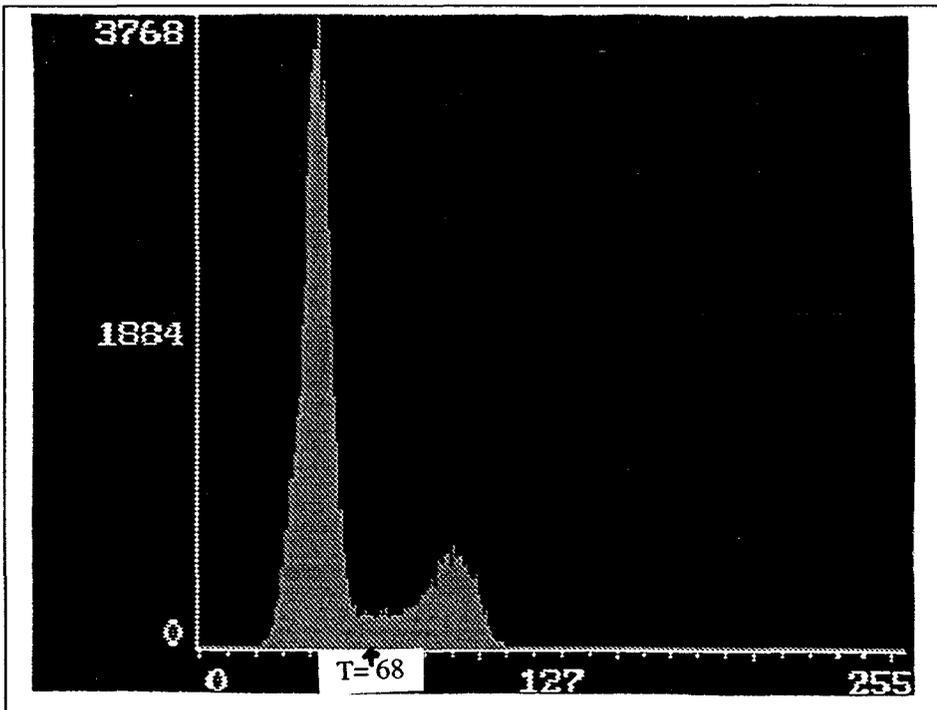


Fig. V-9 : Histogramme de l'image.

La seconde image synthétique étudiée (fig. V-10), résultant de l'application de plusieurs applications d'un filtre morphologique en niveau de gris sur une image composée de points répartis sur un fond sombre permet d'évaluer les performances de notre algorithme lorsque l'histogramme de l'image ne présente pas une forme bimodale (fig. V-11).

Les deux images suivantes (fig. V-12-a et V-12-b) représentent respectivement le classement des points en trois classes au bout de la 20^{ème} et de la 30^{ème} itération de l'algorithme. Après 50 itérations, l'image binaire permet d'identifier les deux types de régions (fig. V-13). On constate également que les régions identifiées épousent les contours des régions de l'image originale. Ceci montre donc que les deux régions ont été correctement identifiées.

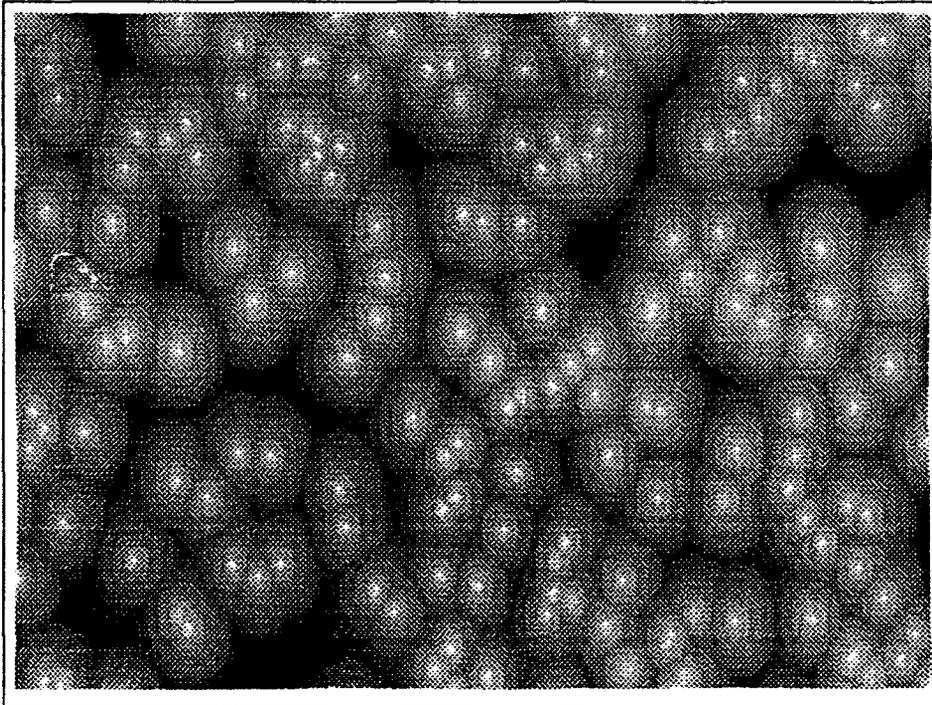


Fig. V-10 : Image originale.

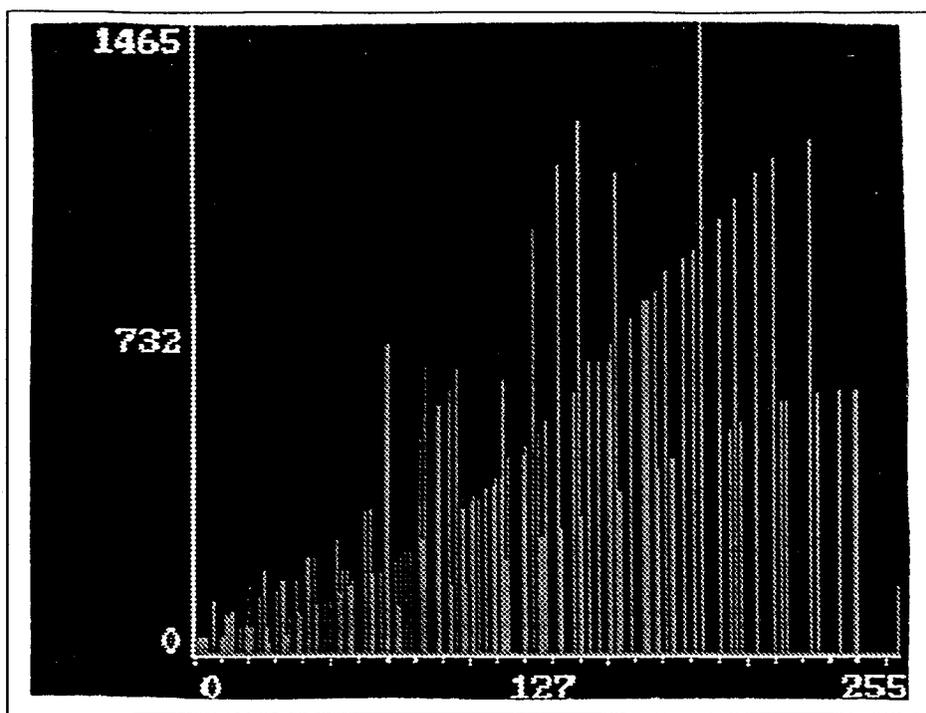
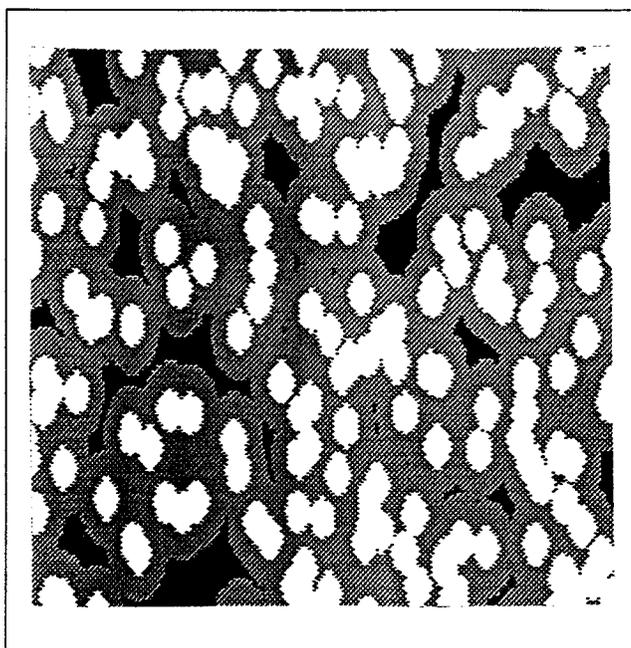


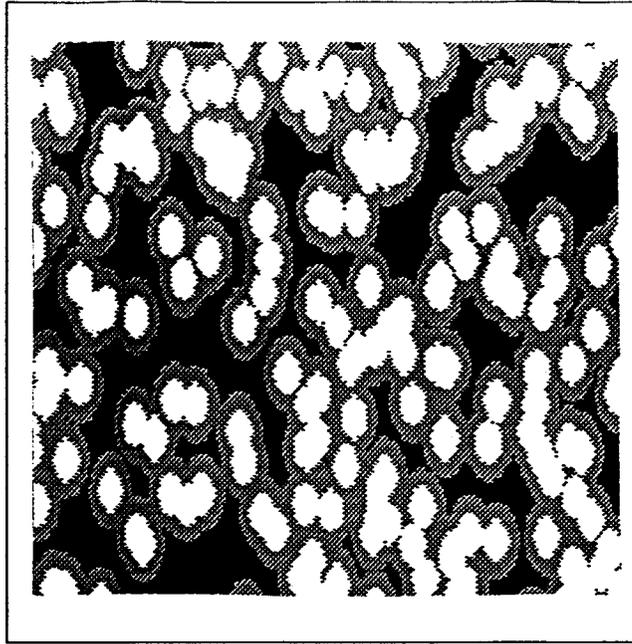
Fig. V-11 : Histogramme de l'image.



(a)

Fig. V-12 : Classement des points.

a- Au bout de la 20^{ème} itération.



(b)

b- Au bout de la 30^{ème} itération.

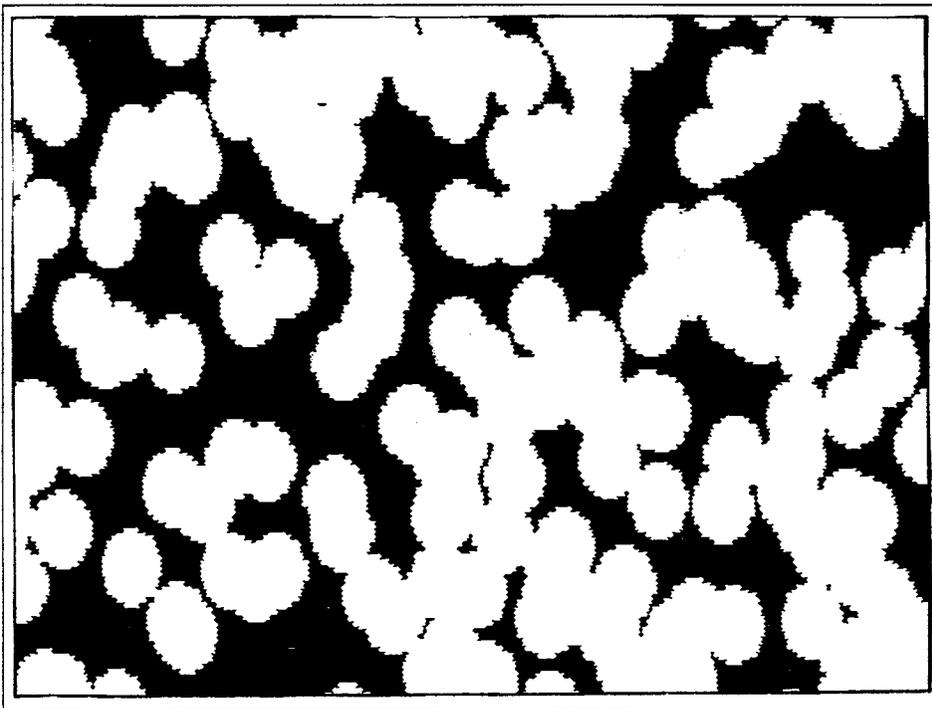


Fig. V-13 : Image binaire.

III CONCLUSION.

La prise en compte simultanée des niveaux de gris des points et de leurs relations spatiales dans l'image conduit à la sélection d'un seuil permettant d'identifier deux types de régions homogènes dans l'image en évitant tout éclatement ou dissémination des points-image qui les constituent. Cette approche de segmentation se trouve d'autant plus intéressante que l'histogramme des niveaux de gris des points de l'image présente une forme unimodale ne permettant pas de distinguer les différentes distributions statistiques des niveaux de gris de chaque type de régions. Notre approche tire ses performances de la stratégie de fusions hiérarchique des régions ainsi que de la constitution des régions initiales.

- CONCLUSION -

CONCLUSION GENERALE.

Aucune valeur de seuil, aussi judicieusement choisie, ne peut permettre une segmentation correcte d'une image si les conditions d'éclairage ne s'y prêtent pas. C'est pour cette raison que le premier chapitre a été entièrement consacré à l'étude de la segmentation des images prises dans de mauvaises conditions d'éclairage. Parmi les différentes catégories de variations d'illumination provoquées par le système d'éclairage, nous avons porté un intérêt particulier à celle de type spatial basse fréquence. En effet, on dispose, de peu de moyens matériels pour améliorer la qualité des images soumises à de telles variations d'illuminations produites par les systèmes d'éclairage. Deux principales alternatives se dégagent pour segmenter des images prises dans de telles conditions d'éclairage.

La première regroupe les approches de seuillage adaptatif. La division arbitraire de l'image en fenêtres rend souvent inapte toute segmentation par ce principe. Ces approches sont plutôt réservées aux images dont les objets sont disposés uniformément sur le fond afin d'éviter qu'une zone homogène ne soit recouverte par un grand nombre de fenêtres unimodales. Toutefois, il reste le problème délicat du choix de la forme et de la dimension des fenêtres. En présence d'images de natures très diverses, ajuster la forme et la dimension des fenêtres reste très délicat.

La seconde alternative vise, quant à elle, à rendre l'image apte à une approche de seuillage global. Sous l'hypothèse selon laquelle les niveaux de gris des points du fond reflètent avec une bonne approximation les variations spatiales basses fréquences du système d'éclairage utilisé, le principe de ces approches consiste à modéliser les variations d'illumination à partir des niveaux de gris de ces points. Par conséquent, plus les objets occupent une surface importante du champ de vision, plus le modèle s'écarte des variations réelles de l'éclairage. Des variations de niveau de gris subsistent alors dans l'image originale de laquelle les variations d'illumination ont été retranchées. Un simple seuillage sur l'image différence obtenue ne peut alors aboutir à une segmentation significative de l'image analysée. Cette seconde alternative est donc réservée aux cas des images pour lesquelles les objets occupent une faible surface du champ visuel. La restriction de son champ d'application à de telles images nous a amenés à améliorer ce principe de modélisation des variations spatiales basses fréquences de l'illumination. Notre approche tire ses performances de la nature itérative

du processus de modélisation qui permet d'obtenir de proche en proche, un modèle de plus en plus représentatif des variations réelles de l'éclairage. Cette approche est d'autant plus intéressante que les objets occupent une surface importante du champ visuel de la caméra.

Dans le second chapitre, la segmentation des images par seuillage global est vue sous l'angle de la classification statistique des données. La théorie de la **décision optimale** repose sur des règles simples. Cette théorie nécessite une **base de connaissances a priori** sur l'image très importante. Plusieurs nouvelles **approches** statistiques de segmentation, faisant appel à une base de connaissances moins importante que celle exigée par l'approche optimale ont été élaborées. Deux principales approches les composent. Hormis l'hypothèse normale selon laquelle les populations de points sont distribuées normalement, ces deux approches ne font appel à **aucune** connaissance a priori sur les distributions statistiques des niveaux de gris associées aux populations des points de l'image. La première approche consiste à **définir** un critère évaluant le degré de ressemblance entre l'histogramme des niveaux de **gris** de l'image étudiée et la modélisation normale des deux populations de points qui le composent. Il est à signaler, qu'en général, le seuil trouvé diffère peu du seuil fourni par la théorie de la décision optimale. La seconde approche définit de manière itérative un seuil dont la valeur est déterminée à partir de l'équation théorique vérifiée par le seuil de la loi de décision optimale.

Le risque d'une mauvaise classification des points-image se trouve, dans **bien** des cas, très élevé si les distributions de l'histogramme analysé sont bruitées et se recouvrent partiellement. Pour prendre en compte un écart éventuel entre la **distribution** réelle de chaque classe de points à identifier et sa distribution normale idéale, la démarche que nous proposons au troisième chapitre consiste à retenir la classification des points qui, au sens d'un critère simple, maximise la ressemblance **entre** la distribution réelle de chaque classe constituée et la distribution normale qui lui est associée. Cependant, lorsque l'image à segmenter présente des régions de niveaux de gris moyens similaires ou lorsqu'une région recouvre la quasi totalité de la surface de l'image, l'approche proposée se révèle inutilisable puisque l'histogramme de telles images ne présente qu'un seul mode. Dans ce cas, il peut être intéressant d'associer à chacun des points-image, un vecteur regroupant plusieurs attributs afin d'améliorer la discrimination entre les différentes régions constituant l'image. Cette généralisation au cas multidimensionnel fait l'étude de la fin de ce troisième chapitre. Nous proposons

d'utiliser notre approche dans le cadre d'une classification interactive afin de guider l'opérateur dans sa classification interactive des données analysées afin que ce dernier porte un jugement plus rationnel sur sa démarche intuitive.

Le quatrième chapitre est consacré aux approches de segmentation qui utilisent conjointement l'information statistique et l'information spatiale entre les points-image pour segmenter les images afin de pallier le manque d'information spatiale dans la détermination des seuils de segmentation. Parmi toutes les catégories d'approches existantes, nous nous sommes particulièrement intéressés aux approches par fusions successives plutôt qu'aux approches par divisions successives ou fusions et divisions successives. Les approches par divisions successives ont, en effet, l'inconvénient majeur d'être très sensibles aux irrégularités présentes au sein d'une même région. Cela conduit à un découpage d'une même région en plus petites régions alors qu'elle aurait dû conserver sa forme d'origine. Les approches par divisions et fusions successives sont lourdes d'emploi. Le temps de calcul important qu'elles nécessitent ne favorise pas leur mise en oeuvre. Nous avons vu, par contre, que les approches par fusions successives sont bien adaptées à la segmentation des images de natures diverses.

Bien que notre préférence se porte davantage sur les approches par fusions successives, leur étude dans le chapitre précédent nous ont montrés que, avec la plupart des procédures, les résultats obtenus dépendent étroitement de l'ordre dans lequel sont considérés les couples de régions à regrouper. La qualité des approches par fusions successives se trouve également altérée par l'aspect brisé des contours des régions finales issues d'un regroupement de plusieurs régions initiales.

Dans le cinquième chapitre, nous élaborons une nouvelle procédure par fusions successives. L'approche que nous proposons supprime ces deux défauts en définissant, d'une part, une hiérarchie de fusions des couples de régions adjacentes et, d'autre part, on définit chaque région initiale comme un ensemble de points possédant dans l'image des contours d'aspect non rectangulaire.

Nous envisageons, dans un futur proche, d'étendre son principe au cas d'images comportant plus de deux types de régions. Pour cela, nous proposons de décomposer l'histogramme des niveaux de gris de l'image en classes résiduelles et classes sûres par le principe de Jolion [Jol-87]. Les points des classes sûres seront les points

représentatifs des classes à identifier. Il suffira ensuite de faire croître, dans l'image, ces points selon notre principe de fusions hiérarchiques afin d'obtenir une image segmentée en plusieurs types de régions.

- REFERENCES BIBLIOGRAPHIQUES -

REFERENCES BIBLIOGRAPHIQUES

- [Alb-64] R. Albrecht & W. Werner.
Error analysis of a statistical decision method.
I.E.E.E. Trans. Info Theory.
Vol. IT-10, pp. 34-38, 1964.
- [Ame-85] M. Ameziane, P. Bonnet & J.-G. Postaire.
Vision applied to a cutting process in the textile industry.
Proceedings of the 7th International Conference on Automated Inspection and Production.
Control, Birmingham, U.K., pp. 185-194, 1985.
- [Ame-87] M. Ameziane.
Segmentation des images numériques par seuillage multiple.
Application à la découpe automatique dans les ateliers flexibles de confection.
Thèse U.S.T.L.F.A , Lille, 1987.
- [Bal-65] G.H. Ball.
Data analysis in the social sciences : what about the details ?
Proc. F.J.C.C., pp. 533-560, Spartan Books, Washington, D.C. 1965.
- [Bal-82] D.H. Ballard & C.M. Brown.
Computer vision.
Prentice-Hall, Englewood Cliffs, N.J.
pp 119-148, 1982.
- [Bri-70] C. Brice & C. Fennema.
Scene analysis using regions.
Artif. Intelligence.
Vol. 1, pp. 205-226, 1970.
- [Caz-76] P. Cazes.
Décomposition d'un histogramme en composantes gaussiennes.
Revue des statistiques appliquées.
Vol. 24, pp. 63-81, 1976.

- [Cho-73] C.J. Chow & T. Kaneko.
Automatic boundary detection of the left ventricle from cineangiograms.
Computer in Biomedical Research.
 Vol. 5, pp. 388-410, 1973.
- [Cho-89] S. Cho, R. Haralick & S. Yi.
Improvement of Kittler and Illingworth's minimum error thresholding.
Pattern Recognition.
 Vol. 22, N°5, pp. 609-617, 1989.
- [Coo-67] P.W. Cooper.
Some topics on nonsupervised adaptative signal detection for multivariate normal distributions.
Computer & Informatics Sciences - II, pp. 123-146, Academic Press, New York, 1967.
- [Cos-85] J.C. Coster-Chermont.
Précis d'analyse d'images.
Ed. Hermes, pp. 369-372, 1985.
- [Cov-67] T.M. Cover & P.E. Hart.
Nearest neighborpattern classification
I.E.E.E. Trans. Info. Theory.
 Vol. IT-13, pp. 21-27, 1967.
- [Dau-89] D.-G. Daut & D. Zhao.
Mathematical morphology and its application in machine vision.
Visual Communications and Image Processing IV.
SPIE Vol. 1199, pp. 181-188, 1989.
- [Dav-75] L.S. Davis, A. Rosenfeld & J.S. Weska.
Region extraction by averaging and threshoding.
I.E.E.E. Trans. Syst. Man Cybern.
 Vol. SMC-5, pp.383-388, 1975.
- [Dav-80] L.S. Davis.
Image texture analysis techniques : A survey.
In digital image processing.
Ed., Pages 189-201, Bonas, France 1980.

- [Dav-86] G.W. Davis.
Classifying and coping with lighting variation.
Proceedings on the 6th International Conference on Robot Vision and Sensory Controls.
France, pp. 89-98, 1986.
- [Del-87] H. Deleplanque.
Segmentation des images numériques par seuillage adapté.
Application à l'automatisation du repiquage en agriculture.
Thèse U.S.T.L.F.A., Lille, 1987.
- [Dou-89] M.-C. Douchez & J.-G. Postaire.
Splitting and modelling the gray level histogram for threshold selection.
I.E.E.E. Int. Conf. on Image Processing.
ICIP'89, Singapour, 1989.
- [Dou-90-a] M.-C. Douchez & J.-G. Postaire.
Edge pixels classification for automatic threshold selection.
8th IASTED Int. Symp. on Applied Informatics.
Innsbruck, Autriche, pp. 136-139, 1990.
- [Dou-90-b] M.-C. Douchez & J.-G. Postaire.
Segmentation automatique d'images multimodales par classification optimale des niveaux de gris.
12^{ème} journées de Statistique.
Tours, France, pp. 67-68, 1990.
- [Dou-91] M.-C. Douchez & J.-G. Postaire.
An iterative procedure for threshold selection using a connectivity criterion.
9th IASTED Int. Symp. on Applied Informatics.
Innsbruck, Autriche, pp. 76-79, 1991.
- [Dub-80] R. Dubes & A.K. Jain.
Clustering methodologies.
Adv. Comput. Vol.19, 1980.
- [Dub-90] B. Dubuisson.
Diagnostic et reconnaissance des formes.
Ed. Hermes, 1990.

- [Dud-73] R.O. Duda & P.E. Hart.
Pattern classification and scene analysis.
J. Willey, New-York, pp. 88-95, 1973.
- [Ess-89] F. Esson.
Un logiciel de classification interactive multidimensionnelle.
Rapport de D.E.A., USTFA, 1989.
- [Fu-81] K.S. Fu & J.K. Mui.
A survey on image segmentation.
Pattern Recognition.
Vol. 13, pp. 3-16, 1981.
- [Fuk-71] K. Fukunaga & W.L.G. Koontz.
A criterion and an algorithm for grouping data.
J. American Statistical Assn.
Vol. 62, pp. 1159-1178, 1971.
- [Gow-66] J.C. Gower.
Some distance properties of latent root and vector methods in multivariate analysis.
Biometrika, Vol. 53, pp. 325-338, 1966.
- [Har-81] R. M. Haralick & L. Watson.
A facet model for image data.
Computer Vision Graphics and Image Vision.
Vol. 15, pp. 113-129, 1981.
- [Hel-83] H. Hellmut & R.N. Nagel.
Displacement vectors derived from second order intensity variations in image sequence.
Computer Vision Graphics and Image Processing.
Vol. 21, pp. 85-117, 1983.
- [Hor-74] S.L. Horowitz & T. Pavlidis.
Picture segmentation by a directed split and merge procedure.
In Proceedings of the 2nd Int. Conf. on Pattern Recognition.
pp. 424-433, 1974.
- [Jol-86] J.M. Jolion & P. Prevot.
Binarisation automatique d'images en microscopie électronique.
Traitement du signal.
Vol. 3, pp. 153-158, 1986.

- [Jol-87] J.M. Jolion.
Méthodologie de conception de systèmes d'analyse d'images.
Application à la microscopie électronique.
Thèse de Doctorat, INSA Lyon, chap II, 1987.
- [Kan-72] E.P.F. Kan.
Isodata : threshold for splitting clusters.
Technical Report 640-TR-058, Lockheed Electronics Co. Inc. HASD, Houston, Texas, 1972.
- [Kit-85] J.Kittler & J. Illingworth.
On threshold selection using clustering criteria.
I.E.E.E Transactions on systems.
Vol. SMC-15, N°15, 1985.
- [Kit-86] J. Kittler & J. Illingworth.
Minimum error thresholding.
Pattern Recognition.
Vol. 19, N°1, pp. 41-47, 1986.
- [Kli-75] A. Klinger & C.R. Dyer.
Experiments on picture representation using regular decomposition.
Computer Graphics and Image Processing.
Vol. 4, 1975.
- [Kli-78] A. Klinger.
Data structures and pattern recognition.
Proc. first int. joint. Conf. on pattern recognition.
pp. 497-498, 1978.
- [Kra-75] H.P. Kramer & J.B. Bruckner.
Iterations of a non linear transformation for enhancement of digital images.
Pattern Recognition.
Vol. 7, pp. 53-58, 1975.
- [Kru-77] J.B. Kruskal.
Multidimensional scaling and other methods for discovering structures.
Statistic methods for Digital Computers
Vol. 3, pp. 296-339, Wiley, New York, 1977.

- [Llo-85] D.E. Lloyd.
Automatic target classification on using moment invariants of images shapes.
Farnborough, U.K., Rep. RAE IDN AW 126, 1985.
- [Lof-65] D.O. Loftsgarden & C.P. Quesenberny.
A non parametric estimate of a multivariate density function.
Ann. Math. Stat.
Vol. 36, pp. 1049-1051, 1965.
- [Mar-77] A. Martelli.
Edge detection using heuristic search methods.
Computer Vision Graphics and Image Processing.
Vol. 1, N°2, pp. 169-182, 1977.
- [Mar-88] K.V. Mardia & T.J. Hainsworth.
A spatial thresholding for image segmentation.
I.E.E.E. Transactions on Pattern Analysis and Machine Intelligence.
Vol. PAMI-10, N°6, 1988.
- [Mil-78] D.L. Milgram, A. Rosenfeld, T. Willet & G. Tisdale.
Algorithms and hardware technology for image recognition.
Final Report to U.S. Army Night Vision Laboratory, 1978.
- [Mon-87] O. Monga.
A segmentation algorithm and its application to stereovision.
Proceedings of I.E.E. E. International Workshop on Industrial applications of machine vision and machine intelligence.
Roppongi, Tokio, 1987.
- [Mon-88] O. Monga.
Segmentation d'images par croissance hiérarchique de régions.
Thèse de doctorat, Université de Paris Sud, 1988.
- [Mue-68] J. L. Muerle & D.C. Allen.
Experimental evaluation of techniques for automatic segmentation of objects in a complex scene.
In Pictorial Pattern Recognition.
pp. 3-13, Thompson, Washington, 1968.

- [Nak-79] Y. Nakagawa & A. Rosenfeld.
Some experiments on variable thresholding.
Pattern Recognition.
Vol. 11, pp. 191-204, 1979.
- [Par-62] E. Parzen.
On estimation of a probability density function and mode.
Ann. Math. Stat., Vol. 33, pp. 1065-1076, 1962.
- [Pav-72] T. Pavlidis.
Segmentation of pictures and maps through fonctionnal approximation.
Computer Graphics Image Processing.
Vol. 1, pp. 360-372, 1972.
- [Pav-77] T. Pavlidis.
Structure pattern recognition.
Springer Verlag, 1977.
- [Pav-78] T. Pavlidis.
A review of algorithms for shape analysis.
Computer Vision Graphics and Image Processing.
Vol. 7, pp. 243-258, 1978.
- [Pen-86] A. Pentland.
Perceptual organization and the representation of natural form.
AL Journal, Feb. 1986.
- [Pon-84] T.C. Pong, L.G. Shapiro, L.T. Watson & R.M. Haralick.
Experiments in segmentation using a facet model region grower.
Computer Vision Graphics and Image Vision.
Vol. 25, pp. 1-23, 1984.
- [Pos-87] J.-G. Postaire.
De l'image à la décision.
Ed. Dunod, 1987.
- [Rid-78] T. Ridler & S. Calvard.
Picture thresholding using an iterative selection method.
I.E.E.E Trans. Syst. Man Cybern.
Vol. SMC-8, pp. 630-632, 1978.

- [Rob-92] C. Robbe.
Segmentation des images par analyse de la connexité.
Thèse de doctorat, USTLFA, 1992.
- [Ros-56] M. Rosenblatt.
Remarks on some non parametric estimate of a density function.
Ann. Math. Stat.
Vol. 27, pp. 832-837, 1956.
- [Ros-70] A. Rosenfeld.
Connectivity in digital pictures.
J. ACM Vol. 17, pp. 146-156, 1970.
- [Ros-85] A. Rosenfeld & L.S. Davis.
Iterative histogram modification.
T.R. 519 University of Maryland.
- [Sah-88] P.K. Sahoo, S. Soltani, A.K.C. Wong & Y.C. Chen.
A survey of thresholding techniques.
Computer Vision Graphics and Image Processing.
Vol. 41, pp. 233-260, 1988.
- [Sam-70] J.W. Sammon.
A non-linear mapping for data structure analysis.
I.E.E.E. Trans. Computer.
Vol C-18, pp. 401-409, 1969.
- [Seb-84] G.A.F. Seber.
Multivariate observations.
Wiley, New York, 1971.
- [Si-85] Siggraph'85.
Conference Proceeding July 22-26.
San Francisco, CA, Vol. 19(3), 1985.
- [Sok-63] R.R. Sokal & P.H.A. Sneath.
Principles of numerical taxonomy.
W.H. Freeman, San Francisco, Cali., 1963.

- [Tho-78] S. Thome.
Prétraitement du chiffre manuscrit.
Actes du 1^{er} congrès AFCET : Reconnaissance des formes d'intelligence artificielle.
pp. 568-576, 1978.
- [Ton-77] F. Tomita & S. Tsuji.
Extraction of multiple regions by smoothing selected neighborhoods.
I.E.E.E. Trans. Syst. Man. Cybern.
Vol. S.M.C.-7, pp. 107-109, 1977.
- [Tor-86] V. Torre & T.A. Poggio.
On edge detection.
I.E.E.E. Trans. on Pattern Analysis and Machine Intelligence.
Vol. PAMI-8, N° 2, pp. 147-163, 1986.
- [Tru-79] H.J. Trussel.
Comments on picture thresholding using an iterative selection method.
I.E.E.E. Trans. on Syst. Man and Cybernet.
Vol. SMC-9, pp.311, 1979.
- [Tuc-71] J. W. Tuckey.
Exploraty data analysis.
Addison-Wesley, Reading, Mass., 1971.
- [Vog-79] M.A. Vogel & A.K.C. Wong.
SPFS clustering method.
I.E.E.E. Trans on Pattern Analysis Machine Intelligence.
Vol. PAMI-1, N°3, pp. 237-245, 1979.
- [Wan-83] D. Wang, A. Vagnucci & C.C Li.
Digital image enhancement.
Computer Vision Graphics and Image Processing.
Vol. 24, pp. 363-381, 1983.
- [Wes-76] J.S. Weszka, C.R. Dyer & A. Rosenfeld.
A comparative study of texture measures for terrain classification.
I.E.E.E. Trans. on Syst., Man. and Cybernet.
Vol. SMC-6, N°4, pp. 269-285, 1976.

[Wes-78] J.S. Weszka.
A survey of threshold selection techniques.
Computer Vision Graphics and Image Processing.
Vol. 7, pp. 259-265, 1978.



[Wu-82] Y. Wu & A. Rosenfeld.
Threshold selection using quatree
I.E.E.E. Trans. Pattern Anal. Mach. Intell.
Vol. PAMI-4, pp. 90-94, 1982.

[Yan-89] S.D. Yanowitz & A.M. Brukstein.
A new method for image segmentation.
Computer Vision Graphics and Image Processing.
Vol. 46, pp. 82-95, 1989.

[Ye-88] Q.Z. Ye & P.E. Danielsson.
On minimum error thresholding and its implementations.
Pattern Recognition Letters.
Vol. 7, pp. 201-206, 1988.

[Zuc-76] S.W. Zucker.
Region growing : childhood and adolescence.
Computer Graphics and Image Processing.
Vol. 5, pp.382-399, 1976.

