

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOULOUD MAMMERY, TIZI-OUZOU



FACULTE DE GENIE ELECTRIQUE ET DE L'INFORMATIQUE
DEPARTEMENT D'ELECTRONIQUE

Mémoire de fin d'études

Présenté en vue de l'obtention
du diplôme de Master en Électronique

Option : Réseaux et Télécommunication

Thème:

**Segmentation d'images par colonies de fourmis
artificielles hybrides**

Proposé et dirigé par:

Mme : AMEUR Zohra

Étudié et réalisé par:

M^{elle}: FEKRACHE Dalila

Année universitaire **2011/2012**

Remerciements

En premier, je remercie ALLAH de m'avoir donné santé, patience et courage de mener à terme ce modeste travail ;

C'est pour moi autant de plaisir qu'un devoir d'exprimer ma gratitude et ma reconnaissance à Madame AMEUR Zohra pour son effort fourni, ses conseils, sa patience et sa persévérance dans le suivi de mon travail ;

Je remercie également Monsieur HOUASSINE Charif pour son aide, sa disponibilité et pour la patience dont il a fait preuve à mon égard ;

Je voudrai aussi témoigner ma reconnaissance et exprimer toute ma gratitude à mes enseignants qui ont participé d'une grande part dans ma formation ;

Je remercie aussi très sincèrement les membres de jury d'avoir bien voulu accepter d'évaluer mon travail ;

Enfin, j'adresse un grand merci à ma mère, ma famille et mes amis et à toute personne m'ayant aidé d'une manière ou d'une autre et m'ayant soutenu.

Dalila

Dédicaces

Je dédie ce travail à :

La mémoire de mon père qui me doit la toute fierté de ma réussite et que ALLAH le garde dans son vaste paradis;

Ma chère mère qui a éclairé mon chemin et qui m'a encouragé et soutenu tout au long de mes études et que ALLAH la protège et la garde pour nous ;

Mes frères Ramdane, Moumouh, Ouali, K'helifa, Zouhir et Mustafa qui m'ont aidé, soutenu et encouragé tout au long de ma vie ;

Mes sœurs Samia et Rziqa pour leur soutien et patience avec moi ;

Mes belles sœurs Samira, Fatima, Salima et Asma et beaux-frères Djamel et Lyes ;

Mes chers neveux Amine, Anis, Imed à qui je souhaite de réussir leurs examens de BAC et BEM, ainsi que Walid, Mohamed Tahar et mes nièces Meriem, Narimène, Sana, Serine et Amira pour qui je souhaite Inchalah de suivre le meilleur chemin de réussite ;

Mon ami Rabah pour son soutien aux moments difficiles de mon travail et surtout sa patience ;

Tous mes amis et à toutes personnes m'ayant aidé d'une manière ou d'une autre.

Dalila

Table des matières

Introduction générale

Chapitre I

Généralités sur le traitement d'image

| | |
|--|----|
| I.1. Préambule..... | 3 |
| I.2. Système de traitement d'image..... | 4 |
| I.2.1. Acquisition d'une scène..... | 4 |
| I.2.1.1. Définition d'une image..... | 4 |
| I.2.1.2. Image numérique..... | 5 |
| I.2.1.3. Caractéristiques d'une image numérique..... | 7 |
| I.2. Prétraitement des images..... | 10 |
| I.2.1. Filtrage..... | 11 |
| I.2.1.1. Filtres linéaires..... | 11 |
| I.2.1.2. Filtres non linéaires..... | 13 |
| I.2.1.3. Filtres morphologiques..... | 14 |
| I.2.2. Modification d'histogramme..... | 16 |
| I.2.2.1. Notion d'histogramme..... | 16 |
| I.2.2.2. Modification d'histogramme..... | 16 |
| I.2.2.3. Egalisation d'histogramme..... | 17 |
| I.2.2.4. Etirement d'histogramme..... | 17 |
| I.3. Discussion..... | 17 |

Chapitre II Segmentation d'images : Etat de l'art

| | |
|---|----|
| II.1. Préambule..... | 18 |
| II.2. Définition de la segmentation..... | 19 |
| II.3. Etat de l'art des différentes techniques de segmentation..... | 19 |
| II.3.1. Segmentation par région..... | 21 |
| II.3.1.1. Croissance de région (région growing) | 21 |
| II.3.1.2. Fusion des régions (Bottom-up) | 22 |
| II.3.1.3. Division en régions (Top-down) | 22 |
| II.3.1.4. Division/ Fusion (Split and merge) | 23 |
| II.3.2. Segmentation par contours..... | 24 |
| II.3.2.1. Méthodes dérivatives..... | 25 |
| II.3.2.2. Méthodes déformables..... | 29 |
| II.3.3. Segmentation par coopération régions-contours..... | 32 |
| II.3.3.1. Coopération séquentielle..... | 32 |
| II.3.3.2. Coopération mutuelle..... | 32 |
| II.3.3.3. Coopération des résultats..... | 33 |
| II.3.4. Segmentation par classification..... | 34 |
| II.3.4.1. Classification floue..... | 34 |
| II.3.4.2. Classification dure..... | 34 |
| II.4. Domaines d'application de la segmentation..... | 38 |
| II.5. Discussion..... | 39 |

Chapitre III Approches biomimétiques pour la segmentation d'images

| | |
|--|----|
| III.1. Préambule..... | 40 |
| III.2. Méta-heuristiques pour la segmentation..... | 41 |
| III.2.1. Méta-heuristiques à solution unique..... | 42 |
| III.2.2. Méta-heuristiques à base de population..... | 42 |
| III.3. Méta-heuristiques à population en segmentation..... | 43 |
| III.3.1. Algorithmes génétiques..... | 43 |
| III.3.2. Essaim particulaires (EP) | 45 |
| III.3.3. Araignées sociales..... | 47 |
| III.3.4. Réseaux de neurones..... | 49 |
| III.3.5. Systèmes immunitaires..... | 52 |
| III.3.6. Colonies de fourmis artificielle..... | 53 |
| III.4. Discussion..... | 53 |

Chapitre IV Optimisation de la segmentation par Colonies de Fourmis Artificielles

| | |
|---|----|
| IV.1. Préambule..... | 56 |
| IV.2. Fourmis réelles..... | 57 |
| IV.2.1. Anatomie d'une fourmi..... | 57 |
| IV.2.2. Communication entre fourmis..... | 58 |
| IV.3. Fourmis artificielles..... | 59 |
| IV.4. Fourmis réelles/ Fourmis artificielles..... | 59 |
| IV.5. De fourmis réelles aux fourmis artificielles..... | 60 |
| IV.5.1. Optimisation du chemin..... | 60 |

| | |
|---|----|
| IV.5.1.1. Expériences pratiques..... | 60 |
| IV.5.1.2. La méta-heuristique par les fourmis artificielle..... | 62 |
| IV.5.2. Classification..... | 64 |
| IV.6. Segmentation d'images en contours par l'OCF..... | 65 |
| IV.6.1. Formulation de l'OCF..... | 66 |
| IV.6.1.1.Processus d'initialisation..... | 67 |
| IV.6.1.2.Construction de la matrice d'information (visibilité)..... | 67 |
| IV.6.1.3.Déplacement des fourmis..... | 68 |
| IV.6.1.4.Mise à jour..... | 69 |
| IV.6.1.5.Procédé de décision..... | 69 |
| IV.6.2. Algorithme de l'approche proposée | 72 |
| IV.7. Discussion..... | 73 |

Chapitre V Applications et Résultats

| | |
|---|----|
| V.1. Préambule..... | 74 |
| V.2. Méthodologie..... | 75 |
| V.3. Application de la méthode..... | 75 |
| V.3.1. Détection des contours par l'OCF..... | 75 |
| V.3.2. Classification des pixels par l'algorithme des KPPV..... | 76 |
| V.3.3. Application de la méthode hybride proposée..... | 76 |
| V.4. Tests et Résultats..... | 77 |
| V.4.1. Application aux images IRM..... | 77 |
| V.4.2. Application aux images satellitaires..... | 79 |
| V.4.3. Application aux images METEOSAT..... | 82 |

| | |
|--|-----|
| V.5. Interprétation des Résultats..... | 84 |
| V.6. Discussion..... | 86 |
| Conclusion..... | 87 |
| Annexe A..... | A-1 |
| Annexe B..... | B-1 |
| Bibliographie | |

Liste des figures

| | |
|--|----|
| Figure 1 : Système de traitement d'images..... | 4 |
| Figure 2 : Image binaire..... | 5 |
| Figure 3 : Image en niveau de gris..... | 6 |
| Figure 4 : Image couleur..... | 6 |
| Figure 5 : Le voisinage B (5*5) du pixel A..... | 7 |
| Figure 6 : Image montrant le contraste..... | 8 |
| Figure 7 : Image bruitée avec un bruit gaussien..... | 9 |
| Figure 8 : Image floue..... | 9 |
| Figure 9 : Différentes techniques de prétraitement..... | 10 |
| Figure 10 : Image filtrée (Filtre passe-bas) | 12 |
| Figure 11 : Image filtrée (Filtre passe-haut) | 12 |
| Figure 12 : Principe du filtre médian (3*3) | 13 |
| Figure 13 : Application du filtre Médian pour l'image bruitée..... | 13 |
| Figure 14 : Élément structurants..... | 14 |
| Figure 15 : Principe de dilatation sur l'image en niveau de gris..... | 14 |
| Figure 16 : Principe de l'érosion sur l'image en gris..... | 15 |
| Figure 17 : Filtre morphologique (Erosion + Dilatation) | 15 |
| Figure 18 : Schéma représentant les techniques de segmentation..... | 20 |
| Figure 19 : Choix des pixels initiaux..... | 21 |
| Figure 20 : Exemple illustrant la méthode de croissance de région..... | 21 |
| Figure 21 : Principe de la division Quad Tree..... | 22 |
| Figure 22 : Exemple d'application de la technique division..... | 22 |

| | |
|--|----|
| Figure 23 : Image segmentée par la méthode Quad Tree..... | 23 |
| Figure 24 : Exemple de Division/Fusion..... | 23 |
| Figure 25 : Quelques modèles de contours..... | 24 |
| Figure 26 : Détection de contours par différents filtres..... | 27 |
| Figure 27 : Détection de contours par le Laplacien..... | 28 |
| Figure 28 : Utilisation du principe de chainage..... | 29 |
| Figure 29 : Principe du contour actif..... | 30 |
| Figure 30 : Principe de segmentation par contour actif..... | 31 |
| Figure 31 : Principe de la coopération séquentielle..... | 32 |
| Figure 32 : Principe de la coopération mutuelle..... | 33 |
| Figure 33 : Principe de la coopération des résultats..... | 33 |
| Figure 34 : Principe de classification par K-plus proches voisins..... | 36 |
| Figure 35 : Principe de développement d'une méthode biomimétique..... | 40 |
| Figure 36 : Méthodes biomimétiques pour la segmentation..... | 43 |
| Figure 37 : Contours détectés par un algorithme génétique..... | 45 |
| Figure 38 : Extraction de contours effectuée par Essaim Particulaire..... | 47 |
| Figure 39 : Extraction de contours par araignées sociales..... | 49 |
| Figure 40 : Mise en correspondance entre neurone biologique-artificiel..... | 49 |
| Figure 41 : Neurone formel..... | 50 |
| Figure 42 : Quelques fonctions d'activation..... | 50 |
| Figure 43 : Quelques topologies de réseaux de neurones..... | 51 |
| Figure 44 : Détection de contours par ondelettes et réseaux de neurones..... | 51 |
| Figure 45 : Détection de contours par système immunitaire..... | 53 |

| | |
|--|-----|
| Figure 46 : Détection de contours par les colonies de fourmis artificielles | 54 |
| Figure 47 : Anatomie d'une fourmi..... | 57 |
| Figure 48 : Pont binaire de Deneubourg..... | 61 |
| Figure 49 : Expérience du pont avec des branches de tailles différentes..... | 61 |
| Figure 50 : Effet de dépôt d'un obstacle entre la source de nourriture et le nid..... | 62 |
| Figure 51 : Les voisins du pixel $I_{(i,j)}$ (8 et 4 connexions de voisinage) | 67 |
| Figure 52 : Configuration locale pour calculer la variation d'intensité au pixel (i, j) | 68 |
| Figure 53 : Les étapes d'implémentation de l'OCF pour segmenter une image en contours...72 | |
| Figure 54 : Prise de décision sur le résultat trouvé par l'OCF (Si le pixel est contour ou pas)..... | 73 |
| Figure 55 : Etapes de détection des contours par l'OCF..... | 75 |
| Figure 56 : Etapes de segmentation d'images par KPPV..... | 76 |
| Figure 57 : Les étapes de la méthode hybride proposée..... | 76 |
| Figure 58 : Résultats obtenus dans l'application de notre méthode sur des images IRM..... | 78 |
| Figure 59 : Résultats obtenus dans l'application de notre méthode sur des images satellitaires..... | 81 |
| Figure 60 : Résultats obtenus dans l'application de notre méthode sur des images METEOSAT..... | 84 |
| Figure 61 : Images à rayons X..... | B-1 |
| Figure 62 : Appareil IRM..... | B-2 |
| Figure 63 : Image IRM..... | B-2 |
| Figure 64 : Image nucléaire..... | B-3 |

Liste des tableaux

| | |
|--|----|
| Table 1 : Les masques des filtres usuels..... | 27 |
| Table 2 : Algorithme des K-plus proches voisins..... | 37 |
| Table 3 : Principe d'un algorithme génétique..... | 44 |
| Table 4 : Principe de l'algorithme d'essaim particulaire..... | 46 |
| Table 5 : Comparaison entre les fourmis réelles et artificielles..... | 59 |
| Table 6 : Les étapes de construction de la solution..... | 66 |
| Table 7 : Les valeurs des paramètres de l'OCF retenues dans notre étude..... | 85 |

Introduction générale

D'une année à une autre, l'informatique se développe avec les nombreux systèmes et techniques utilisés qui permettent d'ouvrir une voie de développement très prometteuse, notamment dans le domaine du traitement et de l'analyse de l'image qui sont utilisés dans des applications très diverses et variées (météorologie, biologie et médecine, industrie, robotique, agriculture, etc.).

Dans la chaîne du traitement et l'analyse de l'image, l'information d'un bas niveau issue de la phase d'acquisition est transformée en une information de haut niveau où les formes et les structures sont décrites d'une manière synthétique par extraction des informations intéressantes et interprétation de ces informations pour pouvoir décider d'une action.

Cette transformation est obtenue par le passage de quatre étapes essentielles qui sont : l'acquisition, le prétraitement, la segmentation et l'interprétation. Le traitement de bas niveau est donc consacré au prétraitement qui consiste au traitement numérique au sens large, tels que le processus de filtrage et de l'amélioration de la qualité de l'image. Tandis que, le traitement de haut niveau est dédié aux opérateurs d'analyse des images résultantes, telles que la description, la reconnaissance ou encore l'interprétation. Pour pouvoir décrire de façon quantitative et qualitative les objets présents dans l'image.

La segmentation est une étape primordiale de cette chaîne de traitement d'images puisqu'elle conditionne la qualité de l'interprétation, puis la prise de décision. Elle constitue un axe très important de recherche parce que le chemin qui mène à sa résolution est encore ouvert et fastidieux. Elle joue un rôle important dans le processus d'analyse de l'image. Elle fournit une description de la scène. Elle extrait les caractéristiques pertinentes et elle permet le passage d'une représentation en intensité lumineuse à une représentation symbolique.

Plusieurs techniques de segmentation existent : segmentation par régions dans laquelle l'image est segmentée en régions en regroupant les pixels adjacents similaires selon un certain critère d'homogénéité, la segmentation par contours permet quant à elle de détecter les transitions entre les régions de l'image, puis la segmentation par coopération régions contours peut se définir comme une entre-aide entre ces deux concepts (régions-contours) afin d'améliorer le résultat final et par la classification, l'image est segmentée en plusieurs classes.

La bonne méthode sera donc celle qui permettra d'aboutir aux résultats souhaités et à une bonne interprétation. A cet effet, plusieurs approches ont été proposées et même implémentées y compris les méta-heuristiques. Les méta-heuristiques sont des algorithmes généraux d'optimisation applicables pour résoudre une grande variété de problèmes d'optimisation. Elles sont généralement inspirées de la nature : de la biologie (Algorithmes génétiques, systèmes immunitaires, etc.), l'éthologie (colonies de fourmis, etc.).

Notre travail est consacré à la méthode de segmentation par Colonies de Fourmis Artificielles hybridée avec l'algorithme de classification des K-Plus Proches Voisins qui sera appliquée aux différents types d'images (IRM, satellitaires, METEOSAT).

Le travail que nous proposons dans ce mémoire est composé de cinq chapitres, organisés de la manière suivante :

Le premier chapitre « Généralités sur le traitement d'images » consacré à la présentation du système de traitement d'images, ainsi que les différentes méthodes de prétraitement opérant sur l'image afin d'extraire les informations les plus pertinentes.

Le deuxième chapitre « Segmentation d'images : Etat de l'art » dédié à la définition de la segmentation, ses différentes méthodes et techniques en donnant l'algorithme de classification par les K-Plus Proches Voisins (KPPV) proposé.

Le troisième chapitre « Approches biomimétiques pour la segmentation d'image » définit les différentes approches biomimétiques adaptées à la segmentation d'images.

Le quatrième chapitre « Optimisation de la segmentation par Colonies de Fourmis Artificielles » est consacré à l'étude des fourmis artificielles en segmentation d'images en donnant les différentes notions sur les fourmis et les détails de l'algorithme d'Optimisation par Colonies de Fourmis (OCF) proposé pour la détection des contours des images.

Le cinquième chapitre « Applications et Résultats » est dédié à l'application de la méthode proposée sur les différents types d'images utilisées. Nous commençons par l'application de l'OCF pour la détection des contours, ensuite l'application des KPPV pour la classification de pixels et détection des régions et nous terminons par l'hybridation des deux algorithmes pour des résultats plus efficaces, plus intéressants et plus pertinents.

Nous terminons notre travail par une conclusion générale dans laquelle nous récapitulons nos contributions et proposons des perspectives sur la base de notre travail.

Chapitre I

Généralités sur le traitement d'images

I.1. Préambule

Le traitement d'image peut être défini comme l'ensemble des méthodes et techniques opérant sur l'image afin d'extraire les informations les plus pertinentes ou simplement pour fournir une image plus perceptible à l'œil humain.

Le traitement d'image et ses techniques associées sont destinés à exploiter au mieux l'information contenue dans l'image puisque cette dernière désigne l'élément le plus significatif dans le domaine de l'échange de l'information.

I.2. Système de traitement d'image

Un système de traitement d'images peut contenir quatre étapes illustrées par la figure :



Figure 1 : Système de traitement d'images

I.2.1. Acquisition d'une scène

Pour toute chaîne de conception et de production d'images, l'acquisition constitue l'étape préliminaire. Pour pouvoir manipuler une image sur un système informatique, il est nécessaire de lui faire subir une transformation qui la rendra lisible et manipulable sur ce système, c'est la numérisation.

L'acquisition et la numérisation se font en plusieurs étapes :

- ✓ Transfert d'images : c'est le passage du signal optique au signal analogique ;
- ✓ Échantillonnage du signal analogique ;
- ✓ Quantification : consiste à traduire les échantillons en valeurs binaires avec utilisation de codes précis.

I.2.1.1. Définition d'une image

On peut définir une image comme la représentation visuelle d'une scène ou d'une personne par plusieurs moyens (photo, portrait, peinture...etc.).

En traitement de signal, l'image se définit comme étant un signal bidimensionnel.

En mathématique par contre, c'est une application d'un sous-ensemble $M*N$ de $R*R$

vers l'ensemble des réels R qui à chaque couple de réels (x,y) est associé le réel $f(x,y)$ [1] :

$$\begin{array}{lcl}
 f : M*N & \longrightarrow & R \\
 (x,y) & \longrightarrow & f(x,y)
 \end{array} \tag{I.1}$$

L'image peut donc être décrite par une fonction $f(x,y)$ tel que :

f : fonction d'intensité lumineuse définie sur un domaine borné ;

(x,y) : coordonnées linéaires d'un point de l'image.

Mais sous cette forme, l'image reste inexploitable dans le domaine de l'informatique, d'où la nécessité de la numérisation.

I.2.1.2. Image numérique

C'est une image dont la surface est divisée en éléments de tailles fixes appelées cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs prélevé à l'emplacement correspondant dans l'image réelle, ou calculé à partir d'une description interne de la scène à représenter [2].

On distingue deux grandes catégories d'images :

- ✓ Bitmap (images matricielles) : ce sont des images pixélisées, présentes sous forme d'un ensemble de points (pixels) contenus dans un tableau, chacun de ces points possédant une ou plusieurs valeurs décrivant sa couleur ;
- ✓ Vectorielles : ce sont des représentations d'entités géométriques telles qu'un cercle, un rectangle ou un segment. Ceux-ci sont représentés par des formules mathématiques (un rectangle est défini par deux points, un cercle par un centre et un rayon, une courbe par plusieurs points et une équation).

Dans ce qui suit nous donnerons trois exemples d'images numériques :

a) Image binaire

C'est une image dont les pixels ne peuvent avoir que les valeurs 0 et 1. Le 0 correspond à un pixel noir et 1 à un blanc. Le niveau de gris est donc codé sur un seul bit [3].



Figure 2 : Image binaire

b) Image à niveau de gris

Dans une image en niveau de gris (nuances de gris), la couleur d'un pixel peut prendre des valeurs allant de *noir* (0) au *blanc* (255) en passant par un nombre fini de niveaux intermédiaires obtenus par dégradation du noir. Le pixel est ainsi codé sur un octet [4].



Figure 3 : Image en niveau de gris

c) Image en couleurs

Celle-ci est obtenue par la combinaison de trois couleurs primaires : rouge, vert et bleu (RVB). Chaque couleur est codée comme une image à niveaux de gris, avec des valeurs allant de 0 à 255. Donc, pour un $R=V=B=0$ c'est un noir pur et pour $R=V=B=255$ un blanc pur.

La représentation des images couleurs se fait donc soit par une image dont la valeur du pixel est une combinaison linéaire des valeurs des trois composantes couleurs, soit par trois images distinctes représentant chacune une composante couleur.




Figure 4 : Image couleur

I.1.1.3. Caractéristiques d'une image numérique

Nous citons quelques caractéristiques de l'image numérique :

✓ Le Pixel et son voisinage

L'image numérique est constituée d'un ensemble de points appelés *pixels* (*PIC*ture *Elément*) qui représente ainsi le plus petit élément constitutif d'une image numérique, l'ensemble de ces pixels est contenu dans un tableau à deux dimensions constituant l'image.

Les pixels du voisinage sont donc ceux qui entourent le pixel en question, une fenêtre à dimension impaire (3*3,5*5..etc.).




Figure 5 : Le voisinage B (5*5) du pixel A

✓ La Résolution

Déterminée par le nombre de points par unité de surface, exprimé en points par pouce (PPP, en anglais DPI pour Dots Per Inch) ; un pouce représente 2,54 cm [5].

✓ La Luminance

Détermine le degré de luminosité de chaque point de l'image. Elle est définie comme le quotient de l'intensité lumineuse d'une surface [6].

La luminance d'une image numérique en niveau de gris est définie comme la moyenne des pixels de l'image :

$$\text{Lum (I)} = \frac{1}{m*n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} I(x, y) \quad (\text{I.2})$$

m : nombre de colonnes, n : nombre de lignes et $I(x, y)$: la valeur di niveau de gris dans le point (x, y).

✓ Le Contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et claires. Le contraste est défini en fonction des luminances de deux zones d'image.

Soient L_1 et L_2 les degrés de luminosité respectivement de deux zones voisines.

Le contraste est défini par le rapport : $C = \frac{L_2 - L_1}{L_2 + L_1}$ [5] (I.3)




Figure 6 : Image montrant le contraste

Le L_1 représente l'os et le L_2 représente les poumons

✓ La Similarité

La similarité est à la base de tout système de comparaison des pixels d'images, il s'agit de définir une fonction de similarité entre les intensités lumineuses des pixels.

✓ L'Homogénéité

C'est un prédicat qui se base souvent sur des critères statistiques (moyenne, variance).

Soit I une image et A une région de l'image I : l'estimation de la moyenne de I sur A est :

$$\mu(A) = \frac{1}{|A|} \sum_{(x,y) \in A} I(x,y) \quad (\text{I.4})$$

Avec $|A|$ le cardinal de A ; L'estimation de la variance de A est :

$$\sigma^2(A) = \frac{1}{|A|-1} \sum_{(x,y) \in A} (I(x,y) - \mu(A))^2 \quad (\text{I.5})$$

Le critère d'homogénéité entre deux régions A et B est vrai si :

$$|\mu(A) - \mu(B)| < a \min(\sigma(A), \sigma(B)) \quad (\text{I.6})$$

Où a est un paramètre défini par l'utilisateur.

✓ Le Bruit

Un bruit dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur [7].

La figure illustre une image bruitée avec un bruit gaussien.



(a) : image originale



(b) : image bruitée

Figure 7 : Image bruitée avec un bruit gaussien

✓ Flou

C'est la perte de netteté d'une image numérique. Ce flou numérique peut venir d'un mouvement soudain du photographe ou bien du capteur de l'appareil numérique.

La figure suivante illustre une image floutée.



(a) : image originale



(b) : image floutée

Figure 8 : Image floue

✓ La Région

C'est un ensemble de pixels connexes et homogènes. On dit qu'un pixel appartient à une région donnée s'il vérifie les caractéristiques de celle-ci (intensité, centre de gravité...). Les régions voisines sont séparées par des limites ou contours [5].

✓ Le Contour

Un contour est un ensemble de pixels formant une frontière entre deux ou plusieurs régions voisines, où la limite entre deux pixels dont le niveau de gris représente une différence significative. Le contour peut être défini dans la théorie des graphes par un chemin fermé, tel que, les sommets sont les pixels et la variation d'intensité entre les pixels représente les arrêtes.

I.2. Prétraitement des images

Les images numériques telles qu'elles sont acquises, sont très souvent inexploitable pour le traitement d'images parce qu'elles contiennent des défauts tels que le bruit. Pour remédier à cela et selon le besoin, différents prétraitement pour l'amélioration ou la correction sont effectués.

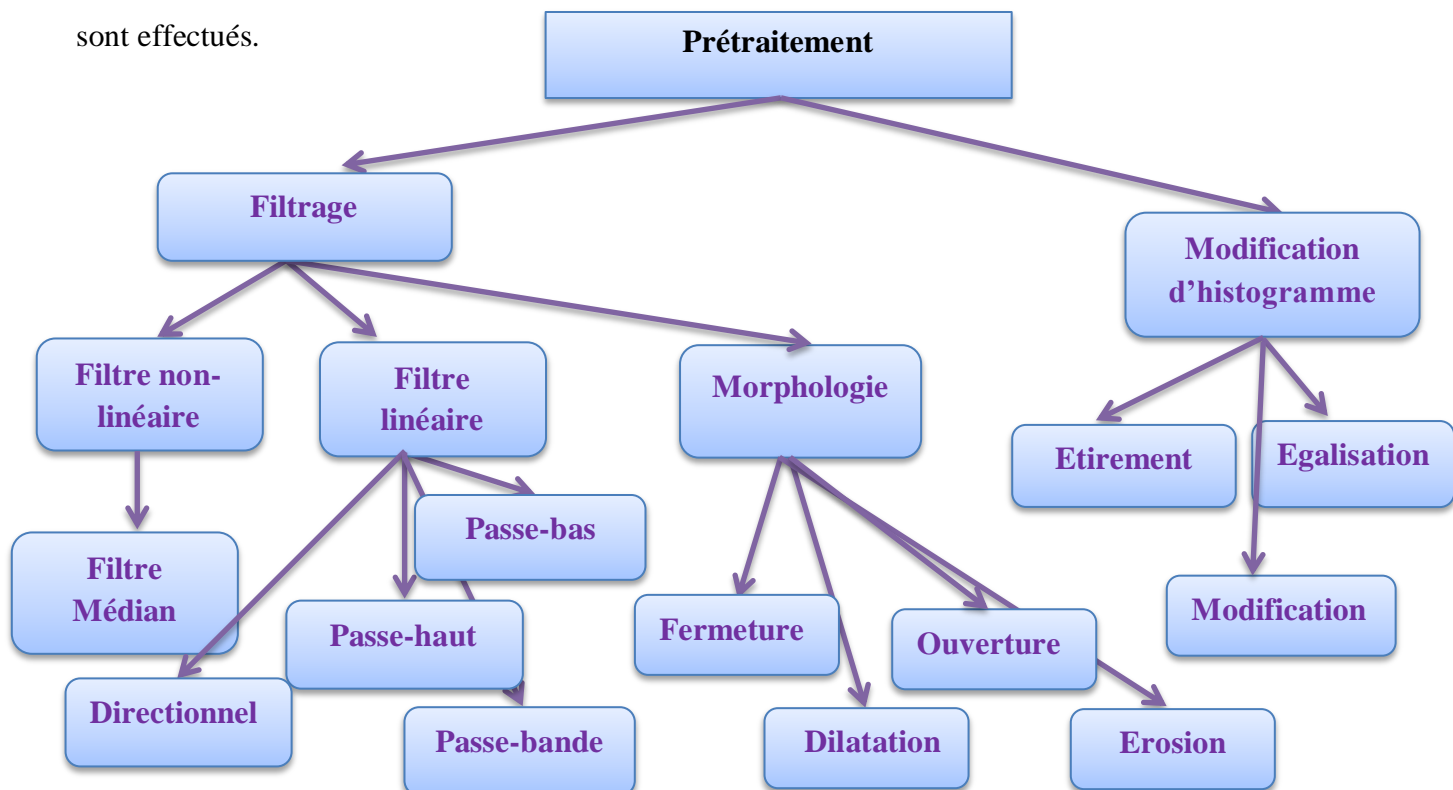


Figure 9 : Différentes techniques de prétraitement

I.2.1. Filtrage

On définit trois types de filtres :

- ✓ Filtres linéaires ;
- ✓ Filtres non linéaires ;
- ✓ Filtres morphologiques.

I.2.1.1. Filtres linéaires

Ils transforment un ensemble de données d'entrée en un ensemble de données de sortie par une convolution qui est une opération mathématique. Ils permettent de supprimer le bruit dans l'image. Chaque filtre a une taille $N \times N$ avec N impair.

Le filtrage est la convolution d'une image $I(x,y)$ avec une fonction $F(x, y)$ qui s'appelle réponse impulsionnelle du filtre.

Dans le cas discret, les domaines de I et de F sont bornés. Le domaine de I est de

$[-n/2 ; +n/2]$ et celui de F est de $[-k/2 ; +k/2]$.

Tel que n^2 est la taille de l'image et k^2 est la taille de la fenêtre de traitement.

a) Filtres passe-bas

Ces filtres permettent d'atténuer les composantes à hautes fréquences de l'image (les pixels claires). Ils lissent ainsi le signal, adoucissent les variations brutales d'intensité, ils éliminent le bruit et modifient assez peu l'image et gardent généralement intacte l'intensité moyenne de l'image.

Par exemple ; le masque suivant utilise la moyenne non pondérée de ses 8 points voisins :

$$H = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

L'image filtrée $G(x,y)$ est donc définie par :

$$G(x, y) = \frac{1}{9} \sum_i^l = -l \sum_j^l = -l I(x+i, y+j) \quad (\text{I.7})$$



Figure 10 : Image filtrée (Filtre passe-bas)

b) Filtres passe-haut

Ces filtres permettent d'atténuer les composantes à basses fréquences de l'image (les pixels claires). Ils accentuent les détails et le contraste d'une image numérique. Ils ont pour but de rehausser les frontières. Ils mettent en valeur les points isolés ou les limites des objets, alors que les autres points sont mis à 0 (en noir)

Les masques suivants mettent en évidence les gradients positifs suivant l'axe des x et l'axe des y :

$$P_x = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

$$P_y = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$



Figure 11 : Image filtrée (Filtre passe-haut)

c) Filtres passe-bande (Différenciation)

Cette opération est une dérivée du filtre passe-bas. Elle consiste à éliminer la redondance d'information entre l'image originale et l'image obtenue par filtre passe-bas.

d) Filtres directionnels

Ils sont utilisés pour faire apparaître les détails de l'image dans une direction déterminée (horizontale, verticale et diagonale).

I.2.1.2. Filtres non linéaires

Ils sont utilisés pour éviter le flou introduit par les filtres passe-bas classiques. Ce sont des filtres dans lesquels la nouvelle valeur du pixel est calculée par une combinaison non linéaire de la fenêtre des pixels avoisinants [8]. Le plus utilisé est le filtre médian.

✓ Filtre médian

Ce filtre a pour objectif d'éliminer le bruit dans l'image. Il s'agit de remplacer la valeur du pixel par la valeur médiane du pixel et de ses voisins.




Figure 12 : Principe du filtre médian (3*3)

Dans cet exemple, la valeur de niveau de gris de pixel central (le pixel qui a un niveau de gris égal à 40) est remplacée par 30.



Figure 13 : Application du filtre Médian pour l'image bruitée

I.2.1.3. Filtres morphologiques

Les informations morphologiques sont définies à l'aide d'un élément structurant et un opérateur. L'élément structurant est un ensemble de pixels qui possède les caractéristiques suivantes :

- ✓ Une forme géométrique ;
- ✓ Un pixel central noir ;
- ✓ Un ensemble de pixels voisins au pixel central en blanc.




Figure 14 : Élément structurants

Les opérateurs morphologiques les plus usuels sont :

a) Dilatation

Elle permet d'éliminer les points noirs isolés de l'image. Elle élargit les « pics » et comble les « vallées ». Elle peut être répétée jusqu'à ce que l'image ait une valeur constante (la valeur maximale).

Pour chaque pixel $u(i, j)$ de l'image :

1. Centrer l'élément structurant sur ce pixel ;
2. Considérer les voisins du pixel dans l'élément (centre + ses voisins) ;
3. Si l'un de ces pixels est en blanc, mettre $u(i, j)$ en blanc ;

Cependant pour une image en niveau de gris, la valeur du pixel est remplacée par la valeur maximale de ses voisins. La figure suivante montre ce principe :




Figure 15 : Principe de dilatation sur l'image en niveau de gris [6]

b) Erosion

Elle permet d'éliminer les points blancs isolés de l'image. Elle abaisse les « pics » et élargit les « vallées ». Elle peut être répétée jusqu'à ce que l'image ait une valeur constante (la valeur minimale). Pour chaque pixel $u(i, j)$ de l'image :

1. Centrer l'élément structurant sur ce pixel ;
2. Considérer les voisins du pixel dans l'élément (centre + ses voisins) ;
3. Si l'un de ces pixels est en noir, mettre $u(i, j)$ en noir.

Cependant pour une image en niveau de gris, la valeur du pixel est remplacée par la valeur minimale de ses voisins. La figure suivante montre ce principe :




Figure 16 : Principe de l'érosion sur l'image en gris [6].

c) Ouverture

L'ouverture est une érosion suivie d'une dilatation. Elle rase les « pics » de l'histogramme sans modifier les « vallées ».

d) Fermeture

La fermeture est une dilatation suivie d'une érosion. Elle comble les « vallées » sans modifier les « pics ».



(a) Image originale

(b) après érosion

(c) après dilatation

Figure 17 : Filtre morphologique (Erosion + Dilatation)

I.2.2. Modification d'histogramme

I.2.2.1. Notion d'histogramme

L'histogramme des niveaux de gris de l'image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris. L'histogramme permet alors de donner la distribution des niveaux de gris de l'image appelée « dynamique de l'image ».

C'est un outil privilégié en analyse d'image car il donne un résumé simple, mais souvent suffisant du contenu de l'image. On peut distinguer trois types d'histogramme d'image :

a) Histogramme uni modal

Ce type d'histogramme n'a qu'un seul pic, il présente soit un objet soit un fond.

b) Histogramme bimodal

Il est formé de deux modes bien séparés (deux pics séparés par une vallée) et l'on déduit ainsi qu'il existe un objet sur un fond.

c) Histogramme multimodal

Il est formé de plusieurs modes séparés (plusieurs pics séparés par plusieurs vallées) qui nous renseigne sur la présence de plusieurs objets.

I.2.2.2. Modification d'histogramme

L'histogramme est un outil très utile pour étudier la répartition des composantes d'une image. Sa modification est généralement représentée sur une courbe indiquant la modification globale des composantes de l'image avec en abscisse les valeurs initiales et en ordonnées les valeurs après modification. La courbe tonale correspond à une fonction de transfert définie par une table de transcodage appelé look up, notée LUT.

I.2.2.3. Egalisation d'histogramme

L'égalisation d'histogramme est un outil qui est parfois utile pour améliorer certaines images de mauvaise qualité (mauvaise contraste, image trop sombre ou trop claire,...).

Il s'agit de déterminer une transformation f des niveaux d'intensité qui rend l'histogramme aussi plat que possible. Si un pixel a une intensité i dans l'image originale, son intensité dans l'image égalisée est $f(i)$. En général, on choisit pour f une fonction en escalier, et on détermine la largeur et la hauteur des différentes marches de manière à aplatir l'histogramme de l'image égalisée.

I.2.2.4. Étirement d'histogramme

L'étirement d'histogramme consiste à répartir des fréquences d'apparition des pixels sur la largeur de l'histogramme. Ainsi, il s'agit d'une opération consistant à modifier l'histogramme de telle manière à répartir aux mieux les intensités sur l'échelle des valeurs disponibles. Ceci revient à étendre l'histogramme afin que la valeur d'intensité la plus faible soit à zéro et que la plus haute soit à la valeur maximale.

De cette façon, si les valeurs de l'histogramme sont très proches les unes des autres, l'étirement va permettre de fournir une meilleure répartition afin de rendre les pixels clairs encore plus clairs et les pixels foncés proches du noir.

I.3. Discussion

Le traitement de l'image est souvent précédé d'un prétraitement pour une bonne compréhension et connaissance des différentes caractéristiques de l'image, pour pouvoir ainsi augmenter la qualité de celle-ci en appliquant les méthodes de prétraitement appropriées (suppression des bruits par différents filtres,...etc.), sans perdre les informations utiles de l'image, afin d'avoir un bon résultat de segmentation qui est la troisième étape de notre système de traitement d'image.

Chapitre II

Segmentation d'images : Etat de l'art

II.1. Préambule

Une bonne analyse de l'image nécessite la réalisation d'une bonne segmentation de celle-ci, car c'est à partir d'une image segmentée que les mesures sont effectuées pour l'extraction des paramètres discriminants en vue de la classification ou de l'interprétation.

L'objectif de la segmentation d'une image est d'établir une description compacte et représentative de son contenu informationnel, qui est plus exploitable que l'ensemble de ses points. Il s'agit donc, de procéder à l'extraction d'indices visuels (primitives) pertinents, suffisamment corrélés avec les entités qui composent la scène d'où l'image est prise.

Il est bien difficile de donner une définition précise à la notion d'indice visuel. Il peut être défini comme étant une information perceptible directement à partir de la visualisation de l'image (régions, contours).

II.2. Définition de la segmentation

La tâche de segmentation est souvent confondue à celle de classification, c'est pour cela qu'il reste toujours difficile de donner une définition à la notion de segmentation.

Segmenter une image signifie, trouver ses régions homogènes et ses contours, ces deux derniers sont supposés être pertinents, c'est-à-dire que les régions doivent correspondre aux parties significatives des objets du monde réel, et les contours à leurs frontières apparentes.

Soit ' x ' le domaine de l'image et ' f ' la fonction qui associe à chaque pixel une valeur $f(x,y)$ [9]. Si nous définissons un prédicat ' p ' sur l'ensemble des parties de ' x ', la segmentation de ' x ' est définie comme une partition de ' x ' en ' n ' sous-ensembles $[R_1, R_2, R_3, \dots R_n]$ tels que :

- ✓ $X = \cup_{i=1}^n R_i \leftrightarrow$ L'union de toutes les régions donne l'image originale
- ✓ $\forall i ; i = \overline{1, n} \ R_i \text{ est connexe} \leftrightarrow$ Les pixels appartenant à une même région sont connexes
- ✓ $\forall i, j ; i \neq j ; R_i \cap R_j = \emptyset \leftrightarrow$ Deux régions différentes sont disjointes
- ✓ $\forall i ; i = \overline{1, n} \ P(R_i) = \text{vrai} \leftrightarrow$ Chaque pixel satisfait le critère d'homogénéité
- ✓ $\forall i, j ; i = \overline{1, n} ; j = \overline{1, n} ; P(R_i \cup R_j) = \text{faux} \leftrightarrow$ Deux régions différentes sont hétérogènes [3].

R_i et R_j étant deux régions voisines et ' p ' est un prédicat d'homogénéité.

II.3. Etat de l'art des différentes techniques de segmentation

La segmentation joue un rôle prépondérant dans le traitement d'images. Elle est réalisée avant les étapes d'analyse et de prise de décision dans plusieurs processus de traitement d'images, tels que la détection des objets. Elle aide à localiser et à délimiter les entités présentes dans l'image. Plusieurs techniques de segmentation existent et quatre grandes catégories peuvent se distinguer :

- La segmentation par régions ;
- La segmentation par contours ;
- La segmentation par coopération région-contours ;
- La segmentation par classification.

Dans la première catégorie, l'image est segmentée en régions en regroupant les pixels adjacents similaires selon un certain critère d'homogénéité.

Quant à la segmentation par contours, elle permet de détecter les transitions entre les régions de l'image. Les résultats de cette segmentation sont les pixels candidats des limites des objets de l'image.

La coopération régions-contours peut se définir comme une entre-aide entre ces deux concepts (régions-contours) afin d'améliorer le résultat final.

Dans la classification, l'image est segmentée en plusieurs classes en n'utilisant que l'histogramme.

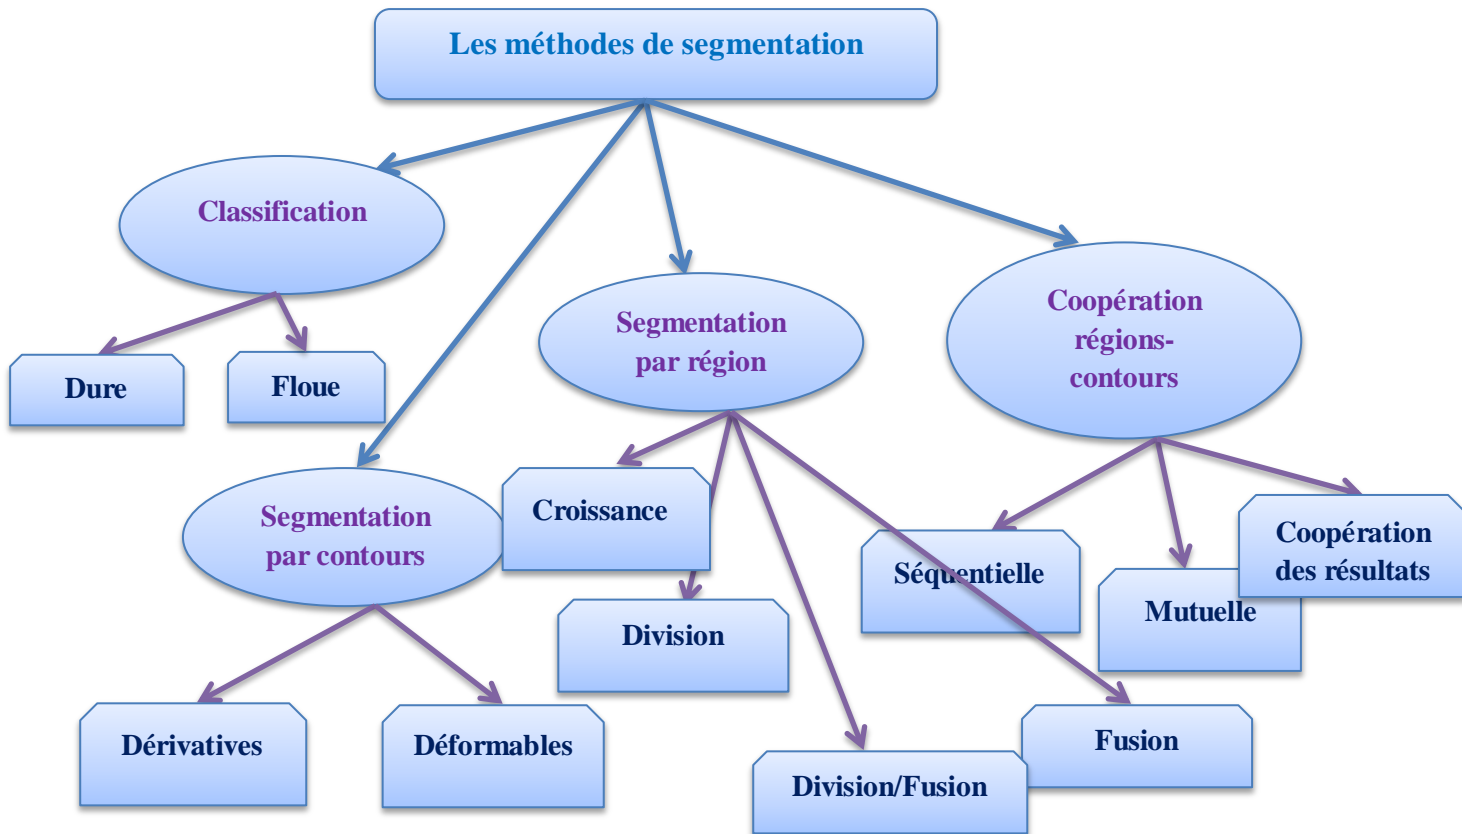


Figure 18 : Schéma représentant les techniques de segmentation

II.3.1. Segmentation par région

Cette segmentation consiste à découper l'image en régions. Les pixels adjacents sont regroupés en régions distinctes selon un critère d'homogénéité ou de similarité donnée. Ce critère peut être le niveau de gris, couleur, texture,...etc.

Un processus de regroupement est répété jusqu'à ce que tous les pixels dans l'image soient inclus dans des régions. Cette approche vise, donc, à segmenter l'image en se basant sur des propriétés intrinsèques des régions.

Plusieurs techniques de cette approche sont à distinguer :

II.3.1.1. Croissance de région (région growing)

C'est une technique ascendante : on part d'un ensemble de petites régions uniformes dans l'image où les points sélectionnés représentent les régions initiales. Ces régions croient au fur et à mesure par l'incorporation des pixels les plus similaires jusqu'à ce que l'image soit couverte [2].



Figure 19 : Choix des pixels initiaux



Croissance progressive d'une région

image finale

Figure 20 : Exemple illustrant la méthode de croissance de région

II.3.1.2. Fusion des régions (Bottom-up)

Cette technique démarre à partir de petits éléments de l'image qu'il va tenter de regrouper en éléments plus importants. La décision de fusion est basée sur un critère d'homogénéité locale qui décrit la similarité entre deux régions adjacentes.

II.3.1.3. Division en régions (Top-down)

L'image entière sera subdivisée récursivement en plus petites régions, tant que ces régions ne sont pas suffisamment homogènes, la méthode est réappliquée sur chacune des régions. La division peut se faire en quatre parties, en six parties, en polygones, etc.

Le découpage s'arrête soit quand toutes les régions sont homogènes, soit quand il n'est plus possible de diviser les régions non homogènes parce qu'elles sont trop petites. Le résultat peut être représenté sous forme d'arbre appelée Quad-Tree [2].





Figure 21 : Principe de la division Quad Tree




Agrandissement d'une partie avant la division

agrandissement de l'image segmentée

Figure 22 : Exemple d'application de la technique division

La figure suivante montre une segmentation d'image par la méthode Quad Tree :



(a) Image originale

(b) image segmentée

Figure 23 : Image segmentée par la méthode Quad Tree

II.3.1.4. Division/ Fusion (Split and merge)

Cette méthode combine les deux précédemment citées : la division de l'image en de petites régions homogènes, puis la fusion des régions connexes et similaires au sens d'un prédicat de regroupement. On part du principe que chaque pixel représente à lui seul une région. Deux régions seront fusionnées si elles répondent aux critères de similarité des niveaux de gris et d'adjacence de régions. On s'arrête dès que le critère de fusion n'est plus vérifié.

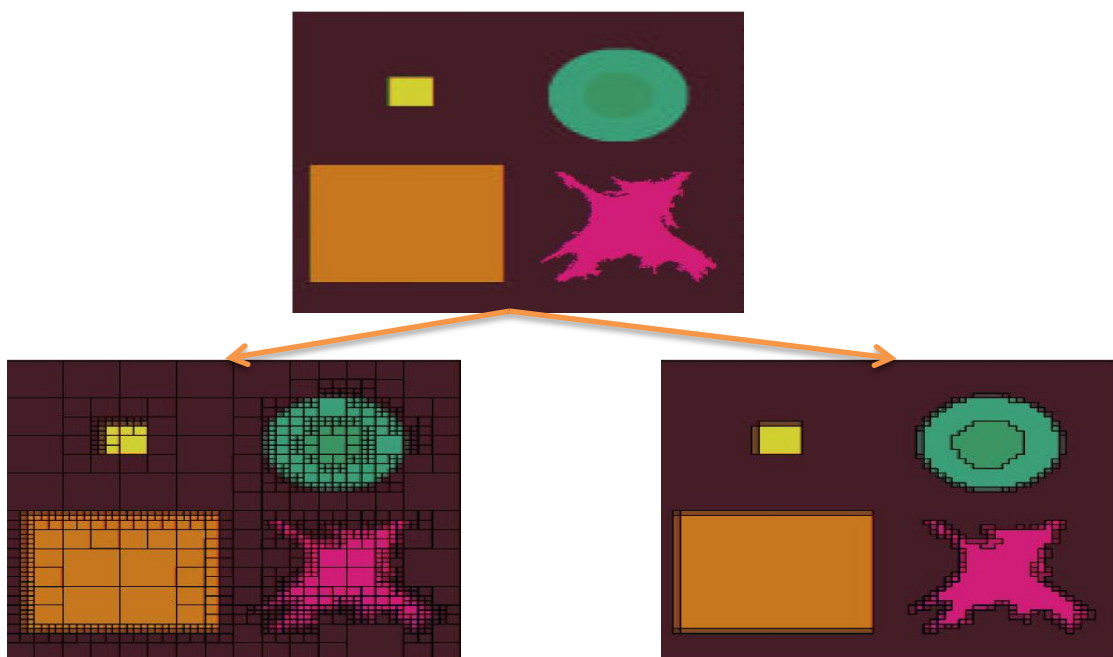


Image segmentée après division

Image segmentée après fusion

Figure 24 : Exemple de Division/Fusion

II.3.2. Segmentation par contours

Pour le traitement d'image, la détermination des limites des objets dans une scène est d'une importance majeure.

Le contour peut être pris comme le bord ou la frontière de deux régions (objets), et la détection des contours est équivalent à détecter les discontinuités à la frontière de deux régions.

Un contour est donc, un ensemble de pixels formant une frontière entre deux ou plusieurs régions voisines, l'épaisseur d'un contour est d'un ou plusieurs pixels et il est défini par une variation "rapide" de caractéristiques (intensité du pixel).

La figure suivante nous montre quelques modèles de contours :




Figure 25 : Quelques modèles de contours [9]

- Marche d'escalier : le contour est net (contour idéal) ;
- Rampe : le contour est plus flou ;
- Toit : il s'agit d'une ligne sur un fond uniforme.

Nous présentons dans ce qui suit les différentes méthodes adaptées pour la détection de contours dans les images en niveaux de gris. Pour ces dernières, deux familles de méthodes sont distinguées :

- ✓ Méthodes dérivatives ;
- ✓ Méthodes déformables.

II.3.2.1. Méthodes dérivatives

Elles sont les plus utilisées pour détecter des transitions d'intensité par différentiation numérique. Ce sont des méthodes locales qui balayent l'image avec un masque définissant la zone d'intérêt.

A chaque position, un opérateur est appliqué afin de détecter les transitions significatives au niveau de l'attribut de discontinuité choisi. Le résultat sera donc, une image binaire constituée de points de contours et de points non-contours.

Pour l'obtention des régions homogènes, il faut appliquer au parallèle que ces méthodes d'autres traitements permettant de fermer les contours ouverts et remplissent les zones délimitées par ces contours. Etant donné que les opérateurs de dérivation sont très sensibles au bruit, les images bruitées doivent être lissées au préalable. Le lissage et la dérivation sont en pratique réunis dans un seul filtre.

De nombreuses techniques d'extraction de contours existent dans la littérature. Elles peuvent être classées dans les catégories suivantes :

- Les algorithmes basés sur le Gradient (opérateurs du premier ordre) ;
- Les algorithmes basés sur le Laplacien (opérateurs du second ordre).

Les méthodes dites dérivatives sont les plus immédiates pour détecter et localiser les variations des niveaux de gris, pour se faire deux étapes sont à distinguer :

a) Extraction

Cette étape consiste à appliquer un produit de convolution sur une fenêtre de l'image par un opérateur (masque) afin d'estimer s'il y'a une transition significative en niveau de gris des pixels [2].

Deux techniques sont mises en œuvre :

➤ Calcul du Gradient (dérivée première)

Les filtres utilisés ici sont des filtres de dérivé première (appelés filtres étroits) et l'on cherche alors les maxima locaux de leurs réponses. Les contours vont correspondre à des maxima locaux de la dérivée première, marquant les fortes variations d'intensité dans l'image. Leur prototype est le filtre de gradient, la dérivée première correspond à ce dernier

est défini par un vecteur composé de la dérivée partielle de l'image selon 'x' et de la dérivée partielle selon 'y'. Chaque pixel $I(x, y)$ a un module et une direction du gradient qui peuvent être établis selon les formules suivantes [5] :

$$\vec{\nabla} I = \frac{\partial I(x,y)}{\partial x} \vec{I_x} + \frac{\partial I(x,y)}{\partial y} \vec{I_y} \quad (\text{II.1})$$

Où $\vec{I_x}$ (resp $\vec{I_y}$) est un vecteur unitaire suivant x (resp y).

Le gradient, en un pixel d'une image numérique, est un vecteur caractérisé par son amplitude et sa direction. L'amplitude est directement liée à la quantité de variation locale des niveaux de gris.

La direction du gradient est orthogonale à la frontière qui passe au point considéré. La méthode la plus simple pour estimer un gradient est donc de faire un calcul de la variation monodimensionnel c'est-à-dire en ayant choisi une direction donnée.

Le gradient étant un vecteur, l'approche la plus classique pour estimer le gradient consiste à choisir deux directions privilégiées (naturellement celles associées au maillage, i. e: ligne et colonne) orthogonales sur lesquelles on projette le gradient. Nous pouvons donc obtenir une connaissance parfaite du gradient de l'image qui se calcule comme suit [5] :

$$\nabla_x = \frac{\partial I(x,y)}{\partial x} \quad \text{et} \quad \nabla_y = \frac{\partial I(x,y)}{\partial y} \quad (\text{II.2})$$

Ainsi, en chaque point de l'image (x, y) , on définit deux dérivées partielles, suivant x et suivant y . la direction du vecteur gradient maximise la dérivée directionnelle et sa norme est la valeur de cette dérivée.

L'approximation des deux dérivées est donnée par la relation suivante :

$$\frac{\partial I(x,y)}{\partial x} = I(x+1, y) - I(x, y) \quad \text{et} \quad \frac{\partial I(x,y)}{\partial y} = I(x, y+1) - I(x, y) \quad (\text{II.3})$$

$$\text{Le module : } G(x, y) = \|\nabla I(x, y)\| = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (\text{II.4})$$

$$\text{La direction (argument) : } \arg G(x, y) = \arctan\left(\frac{G_y(x, y)}{G_x(x, y)}\right) \quad (\text{II.5})$$

Il existe plusieurs opérateurs de gradient qui consistent à estimer le module du gradient en utilisant deux masques de convolution correspondant à la direction horizontale et verticale. Parmi ses opérateurs, il y'a des masques de Roberts, de Prewitt et de Sobel...etc. ([5], [10]).

Ceux-ci sont définis dans le tableau suivant :

| Le nom du filtre | $\frac{\partial I(x,y)}{\partial x}$ | $\frac{\partial I(x,y)}{\partial y}$ |
|------------------|--|--|
| Robert | $\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$ | $\begin{bmatrix} 0 & -1 \\ -1 & 0 \end{bmatrix}$ |
| Prewitt | $\begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$ | $\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$ |
| Sobel | $\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$ | $\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$ |

Table 1 : Les masques des filtres usuels

Les figures suivantes illustres la détection des contours par les différents filtres :



(a) Image originale



(b) Filtre Robert



(c) Filtre de Prewitt



(d) Filtre de Sobel



(e) Filtre de Canny

Figure 26 : Détection de contours par différents filtres

➤ Calcul du Laplacien (dérivée seconde)

Dans cette approche, l'extraction des contours est basée sur le calcul des dérivées secondes, elle se fait à partir d'une seule convolution et n'exploitent pas les maximas mais les passages par zéro de la fonction de l'image, cela signifie que le Laplacien :

$$\nabla^2 I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} \quad \text{est nul} \quad (\text{II.6})$$

L'approximation des deux dérivées est donnée par la relation suivante :

$$\frac{\partial^2 I}{\partial x^2} = I(x+1, y) + 2I(x-1, y) \quad \text{et} \quad \frac{\partial^2 I}{\partial y^2} = I(x, y+1) - 2I(x, y) + I(x, y-1) \quad (\text{II.7})$$

L'estimation de la dérivée seconde étant très sensible aux bruits, il convient de filtrer très fortement l'image avant de mesurer le Laplacien. Les plus simples opérateurs du Laplacien est donné par l'application des masques suivants : [11]

Laplacien de connexité 4 :

$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$

Laplacien de connexité 8 :


$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & -8 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$

Les contours extraits par le calcul Gradient et Laplacien ne sont pas forcément fermés, pour cela une étape de chainage suit l'extraction des contours.

Dans la figure suivante sera représentée la détection de contours par le Laplacien [2] :



(a) Image originale



(b) contours détectés par le Laplacien

Figure 27 : Détection de contours par le Laplacien

b) Chainage

Afin d'avoir des contours connexes (fermés), le chainage se réalise en tenant compte des caractéristiques des objets dans l'image, telle que la forme qui est un critère essentiel pour le regroupement des pixels.

Lors de la présence du bruit, les méthodes précédemment citées procédant par détection puis *chainage* peuvent provoquer une sous segmentation due soit au fait que la détection a échoué car le contraste est insuffisant (dans un point ainsi que dans son voisinage), soit au fait qu'il n'y a pas de portion de contour significatif sur laquelle le processus de chainage peut s'appuyer. La figure qui suit illustre bien ce phénomène :



(a) image originale (b) image obtenue par un filtrage (c) image obtenue par un chainage

Figure 28 : Utilisation du principe de chainage

II.3.2.2. Méthodes déformables

Ces méthodes ont l'avantage de fournir des contours ou surfaces fermés. Elles sont connues sous le nom de contour actif.

Un contour actif est défini comme une courbe minimisant une énergie et évoluant de manière itérative à partir d'une position initiale proche du contour. Cette approche consiste à combiner les deux étapes citées précédemment à savoir l'extraction et le chainage en une seule étape.

Le principe des contours actifs est de faire évoluer un contour initial autour de l'objet d'intérêt vers une position d'équilibre, c'est-à-dire une direction des bords de l'objet à détecter. Entre deux positions différentes du contour (deux itérations), le mouvement des points est fait par une équation impliquant des forces qui agissent sur le contour. Ces forces

dépendent des données de l'image (tel que le gradient et l'intensité) et des propriétés du contour (rigidité, élasticité...) [5].

La position d'équilibre du contour peut être prise comme étant le minimum d'une fonction d'énergie dont la dérivée correspond aux forces à appliquer.

La figure suivante illustre le principe du contour actif :




Figure 29 : Principe du contour actif

Soit $v(s, t)$ la position d'un point de la courbe à un instant t , et x, y les coordonnées cartésiennes d'un point de l'image :

$$v(s, t) = (x(s, t), y(s, t)) \quad \forall (s, t) \in [0, 1] * [0, \infty [\tag{II.8}$$

Nous allons maintenant examiner les différentes énergies mises en jeu ; puisque la fonctionnelle d'énergie attachée au contour actif est composée de trois énergies :

$$E(v) = E_{interne}(v) + E_{externe}(v) + E_{contexte}(v) \tag{II.9}$$

Nous allons par la suite, préciser ces trois types d'énergies :

a) Energie interne

Elle gère la cohérence de la courbure. Elle maintient la cohésion des points et la raideur de la courbure, qui est utilisée comme terme de régulation :

$$E_{interne}(v) = \int_0^1 \left(\frac{\alpha}{2} (s) \|\dot{v}(s)\|^2 + \frac{\beta}{2} \|\ddot{v}(s)\|^2 \right) \tag{II.10}$$

Les termes ' \dot{v} ' et ' \ddot{v} ' sont les dérivées premières et seconde de ' v ' par rapport à ' s ', le terme du premier ordre correspond à la tension. Il prend une valeur importante quand la courbe se distend.

Si $a=0$, la courbe peut présenter des discontinuités. Il s'agit de l'énergie de discontinuité. Le terme du deuxième ordre correspond à la courbure. Il prend une valeur importante lorsque la courbe s'incurve rapidement c'est-à-dire pour l'obtention de coins.

Si $b=0$, la courbe peut prendre une forte convexité, par contre lorsque b est grand, la courbe tendra vers un cercle si elle est fermée ou une droite si elle est ouverte.

b) Energie externe

L'énergie interne gère la régularisation du contour actif. L'énergie externe quant à elle correspond à l'adéquation aux données. Elle prend en compte les caractéristiques de l'image.

c) Energie contexte

C'est l'énergie continue, permet d'introduire des connaissances a priori sur ce qu'on cherche. Les contours actifs par rapport à leur discrétisation, ont une tendance naturelle à se retracer. La minimisation de l'énergie implique une minimisation de distance. La force ballon va tendre à gonfler le contour actif ou accélérer sa rétractation selon le signe de la force introduite. De plus, cette force va permettre de dépasser les contours présentant un faible gradient ainsi de sortir du bruit pour atteindre une frontière plus fortement marquée. Il s'agit d'une force normale au contour en chaque point.

$$F_{ballon}(v(s)) = k \vec{n}(s) \quad (\text{II.11})$$

Où $\vec{n}(s)$ est un vecteur unitaire normal à la courbe en $v(s)$

L'intensité de l'énergie ballon est un scalaire généralement négatif (expansion du ballon) proportionnel à l'aire intérieur du contour. L'image suivante illustre la progression du contour actif.



(a)Initialisation de contour actif (b) Evolution du contour (c)segmentation finale (stabilité)

Figure 30 : Principe de segmentation par contour actif

II.3.3. Segmentation par coopération régions-contours

Cette segmentation peut se définir comme une entre-aide entre ces deux concepts (régions-contours) afin d'améliorer le résultat final. C'est une approche qui peut être une solution pour pallier aux inconvénients des deux approches. Il existe trois formes de coopération région-contour :

II.3.3.1. Coopération séquentielle

Dans cette approche, soit la technique par région, soit celle par contour est appliquée, son résultat est exploité par l'autre technique pour renforcer la définition des critères (paramètres) de la segmentation. L'intégration de l'information provenant de la segmentation par contour dans une segmentation par région est l'une des formes les plus courantes, mais aussi on peut réaliser la segmentation par région en premier lieu puis son résultat sera exploité par la méthode contour [12].

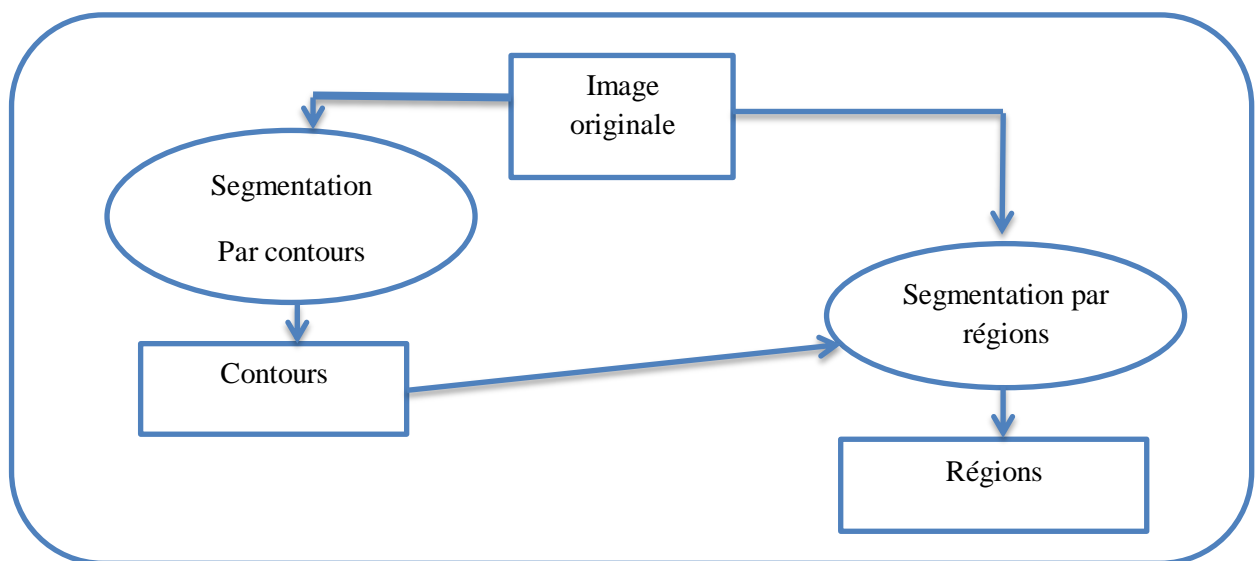


Figure 31 : Principe de la coopération séquentielle

II.3.3.2. Coopération mutuelle

Dans ce cas, les deux techniques de segmentation sont exécutées en parallèle et s'échangent des informations. L'information échangée sert à aider la technique de segmentation dans la prise de décision dans le cas de lacune ou d'informations insuffisantes, elle permet donc de prendre des décisions plus sûres et plus fiables [12].

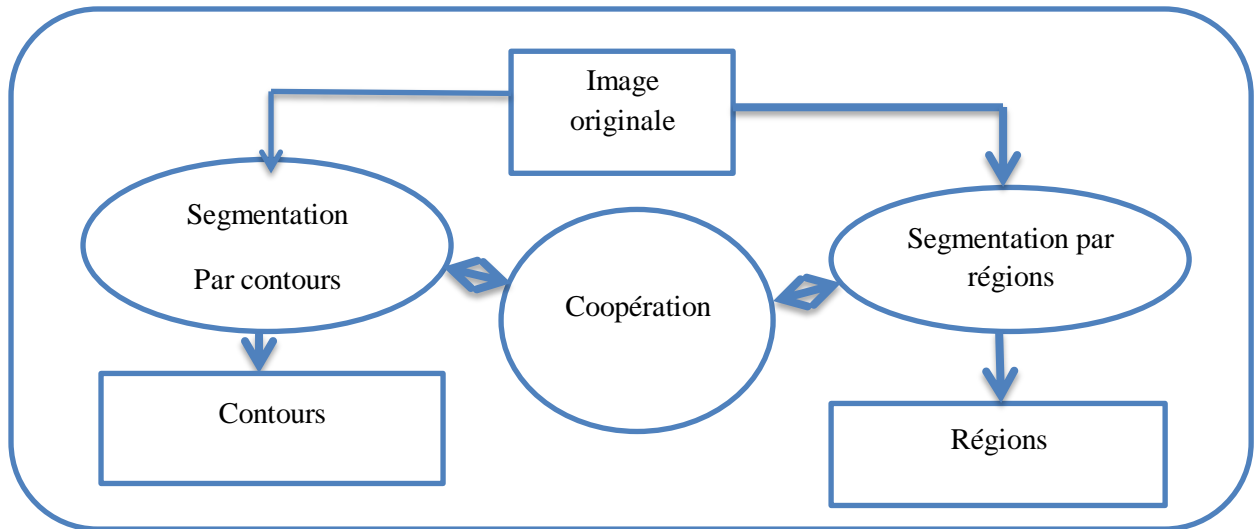


Figure 32 : Principe de la coopération mutuelle

II.3.3.3. Coopération des résultats

Dans cette technique, les deux types de segmentation sont réalisés en parallèle et indépendamment [12]. La coopération est faite au niveau de leurs résultats, ils sont intégrés de façon à atteindre une meilleure segmentation que celle obtenue par une seule technique.

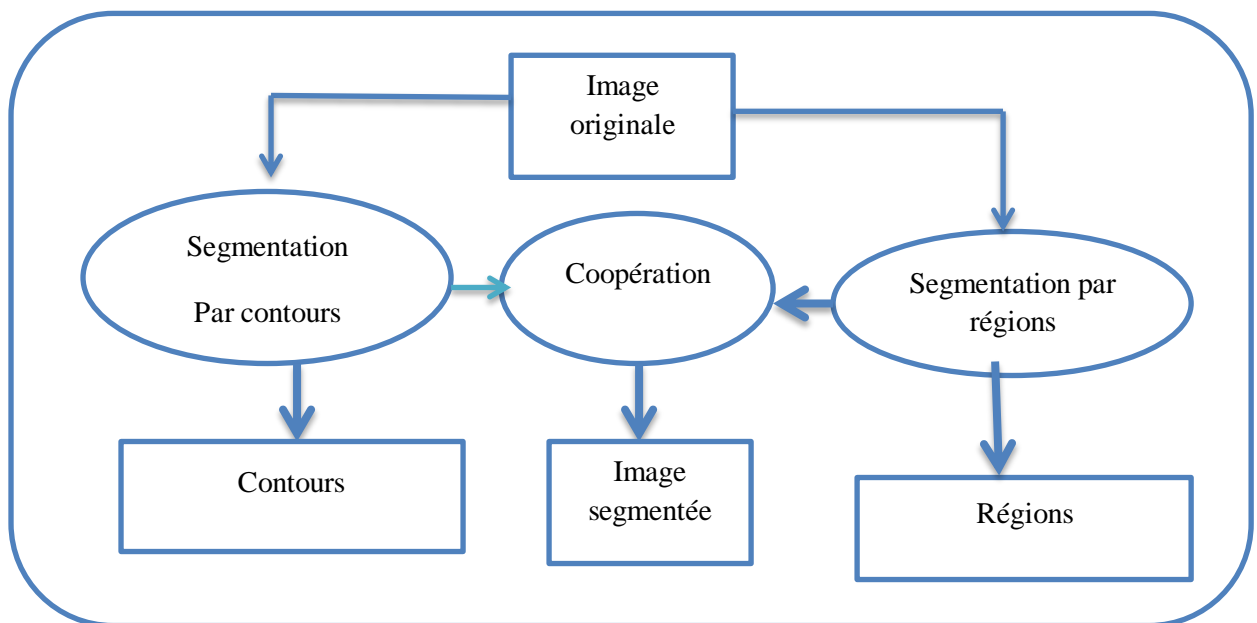


Figure 33 : Principe de la coopération des résultats

II.3.4. Segmentation par classification

La segmentation consiste à "diviser" (partitionner l'image en régions, où chaque région est homogène, au sens d'un critère : forme, texture, couleur,...etc.

La classification consiste à attribuer à chaque pixel dans l'image une classe (étiquette). Cette technique permet de regrouper des pixels ayant des niveaux de gris similaires dans une même classe de pixels. Cette affectation des pixels à des classes peut être effectuée en se basant sur des régions dont on connaît les classes d'appartenance à priori, dans ce cas on parle de *classification supervisée*, ou non, dans ce cas on parle de *classification non supervisée*.

Il n'existe pas une méthode de classification qui peut s'appliquer à tout type d'images et qui peut fournir un partitionnement optimal et le plus naturel possible. Le choix d'une méthode est déterminé par différents facteurs tels que le nombre de classes attendues, la forme des classes extraites ou encore le chevauchement ou non des classes [13].

Il est ainsi possible de regrouper les méthodes de classification sous la forme d'une hiérarchie de méthodes dures et floues [14].

II.3.4.1. Classification floue

Dans une méthode de classification floue, on affecte au pixel un degré d'appartenance pour chacune des classes de la partition qui indique la probabilité que le pixel y appartienne. La classe finale du pixel sera celle pour laquelle son degré d'appartenance est le plus élevé.

A titre d'exemple, on peut citer *l'Algorithme des C-moyennes floues*. Son principe est qu'il n'associe pas directement une classe à un pixel de l'image mais plutôt un degré d'appartenance à une classe (compris entre 0 et 1). Il est basé sur l'optimisation d'un critère quadratique où la somme des écarts quadratiques intra-classes doit être minimale. Les deux paramètres d'entrées de cet algorithme devant être définis au préalable sont respectivement le paramètre de flou et le nombre de classes qui doit être ici supérieur ou égal à 3.

II.3.4.2. Classification dure

Dans une méthode dure, un pixel ne peut être affecté qu'à une seule classe dans la partition de l'image. Elle peut être supervisée ou non supervisée.

a) Classification non supervisée

On parle de classification non supervisée (dite automatique) dans le cas où les classes (étiquettes) sont inconnues, seules les observations (pixels) sont disponibles donc aucune information sur le nombre et le contenu des classes possibles n'est fournie. L'objectif est alors de trouver une partition des pixels en K classes (groupes, régions), telle que les données au sein de la même région sont similaires (au sens d'un critère donné) les uns aux autres comparés aux pixels appartenant aux autres régions. Dans ce cas il s'agit donc, de définir une fonction de similarité entre pixels qui sera maximum entre les pixels d'une même classe et minimum avec ceux des autres classes.

Dans ce type de classification, on peut citer *l'Algorithme des K-moyennes*. Son principe consiste en premier lieu dans la nécessité de définir le nombre de classes avant le début du traitement selon une connaissance préalable (combien de classes sont souhaitées). Ensuite, un nombre de pixels équivalent au nombre de classes est déterminé, ces pixels seront considérés comme étant les centres des classes initiales. Puis, chaque pixel est mis dans la classe ayant le centre le plus proche. Par la suite, on calcule les centres de gravité de ces nouveaux ensembles qui seront considérées à leur tour comme étant les nouveaux centres des classes et on répète l'opération jusqu'à ce qu'il y aura une stabilité des classes et leur centre.

b) Classification supervisée

Dans une classification supervisée, le nombre de classes est connu et on dispose d'un ensemble de pixels déjà étiquetés servant d'ensemble d'apprentissage. Il s'agit alors de pouvoir associer chaque nouveau pixel à la classe la plus adaptée en se servant des pixels déjà étiquetés.

On peut citer *l'Algorithme des K-Plus Proches Voisins* qui est un algorithme de raisonnement à partir de cas, dédié à la classification. Le but de cet algorithme est de prendre des décisions en se basant sur un ou plusieurs cas similaires déjà résolus en mémoire.

Dans ce cadre, il ne construit pas de modèle à partir d'un échantillon d'apprentissage, mais c'est l'échantillon d'apprentissage associé à la fonction de distance et la fonction de choix de la classe en fonction des classes de voisins les plus proches, qui constituent le modèle.

❖ Principe de l'algorithme des K-plus proches voisins

Dans une image, lorsqu'un nouveau pixel à classer arrive. Ses K plus proches voisins sont alors considérés : on observe leur catégorie et celle qui revient le plus parmi les voisins est assignée au pixel à classer. Souvent, on pondère les voisins par la distance qui les sépare du nouveau pixel. Ce principe est donné par :

- Choix d'un entier K (souvent $K=\sqrt{n}$) ;
- Calcul des distances (ex: distance euclidienne, c'est la distance la plus populaire) ;
- Retenir les K observations pour lesquelles ces distances sont les plus petites (les k plus proches voisins d'un cas de référence) ;
- Compter les nombres de fois où ces K observations apparaissent dans chacune des classes (déterminer les classes correspondantes).
- Choisir la classe la plus représentée.

Ces étapes sont résumées comme suit [15] :

Si nous prenons une base d'apprentissage de 20 éléments, dès que nous recevons un nouvel élément que nous souhaitons classifier, l'algorithme calcule sa distance à tous les éléments de la base. Si cette base comporte 20 éléments, alors il va calculer 20 distances et donc obtenir 20 nombres réels. Si $K = 5$ par exemple, il cherche alors les 5 plus petits nombres parmi ces 20 nombres qui correspondent donc aux 5 éléments de la base qui sont les plus proches de l'élément que nous souhaitons classifier. La classe attribuée à l'élément à classifier est la classe majoritaire parmi ces 5 éléments.

Donc, pour le pixel x à classer, après avoir examiné sa distance à tous les échantillons et sélectionner les 5 plus proches échantillons, x sera affecté à la classe w_1 :




Figure 34 : Principe de classification par K-plus proches voisins

❖ Algorithme des KPPV

Les étapes de l'algorithme des K-PPV sont données par le tableau suivant :

Paramètre : le nombre K de voisins

Donnée : un échantillon de N pixels classés en $C = c_1, c_2, \dots, c_n$ classes

Entrée : un pixel Y

Pour chaque pixel Y qui arrive **faire**

1. Déterminer les K plus proches pixels de Y en calculant les distances
2. Combiner les classes de ces K pixels en une classe C

Fin Pour

Sortie : la classe de Y est $C(Y)=C$

Table 2 : Algorithme des K-plus proches voisins

❖ Choix du nombre K

Le choix du paramètre K dans la règle des KPPV a une influence directe sur le résultat de la classification. Une faible valeur de K va donner une bonne résolution (définir des frontières compliquées entre classes) mais très sensible au bruit sur les pixels vecteur à classer. Une valeur grande de K aura un comportement inverse, lissant les frontières mais peu sensible au bruit. Ce nombre est souvent choisi comme étant la racine du nombre d'échantillon total [15].

❖ Distance

Le choix de la distance est primordial au bon fonctionnement de la méthode. En premier, une distance doit avoir quatre propriétés pour tous les pixels x, y et z [15] :

- $D(x, x) = 0$
- $D(x, y) \geq 0$ (II.11)
- $D(x, y) = D(y, x)$ (II.12)
- $D(x, y) \leq D(x, z) + D(z, y)$ (II.13)

Puis, ce choix se fait en fonction des connaissances préalables du problème. Il est possible de choisir la distance en faisant varier cette distance et, pour chacun des choix, estimer l'erreur réelle. On choisit alors la distance donnant la meilleure erreur réelle estimée.

La distance euclidienne entre deux exemples est la préférée :

Soit $A = (A_1, \dots, A_n)$ et $B = (B_1, \dots, B_n)$ deux exemples. La distance euclidienne entre A et B est :

$$D(A, B) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (II.13)$$

La distance euclidienne entre deux pixels x et y est alors définie ainsi :

$$D(x, y) = |x-y| \quad \text{ou} \quad D(x, y) = |x-y|/D_{max} \quad (II.13)$$

D_{max} est la distance maximale entre deux pixels de l'image considérée.

❖ Choix de la classe

Il existe deux manières de sélection des K classes des K voisins les plus proches. La première façon consiste dans le choix de la classe majoritaire. Puis, la seconde façon s'agit de la classe pondérée, c'est-à-dire chaque classe d'un des K voisins sélectionnés, est pondéré. Le poids est inversement proportionnel à la distance entre le cas à classer et les autres K plus proches voisins. En règle générale, il faut considérer un nombre de voisins plus important pour obtenir de bons résultats [15].

Notre application se basera sur la classification supervisée des images à niveaux de gris par l'algorithme des K-PPV qui sera ensuite hybridée avec les colonies de fourmis artificielles, ceci sera l'objet de notre dernier chapitre.

II.4. Domaines d'application de la segmentation

On peut trouver les applications de la segmentation d'images dans plusieurs domaines :

- Médecine (radiographie, tomographie,...), Biologie ;
- Météorologie, Astronomie, Géologie,
- Physique (spectroscopie, physique des plasmas,...) ;
- Application industrielles (robotique, surveillance de qualité,...)
- Photographie et publicité,...

II.5. Discussion

Dans ce chapitre, nous avons donné un état de l'art des méthodes de segmentation d'images les plus connues. L'ensemble des techniques décrites dans cette partie montre que le problème de segmentation reste difficile à traiter d'où la diversité des méthodes de traitement et l'exploration de nouvelles approches en perspectives en introduisant les méta-heuristiques d'optimisation inspirés de la nature, appliquées seules ou hybrides, dans le but d'arriver à une segmentation la plus optimale possible.

La présentation de ces différentes méta-heuristiques d'optimisation de la segmentation d'images sera l'objet du chapitre suivant.

Chapitre III

Approches biomimétiques pour la segmentation d'images

III.1. Préambule

En arrivant à une situation où les techniques existantes ne sont pas précisément adaptées aux cas traités. Ainsi, lorsque l'on veut utiliser une nouvelle méthode de résolution de problèmes, il faut souvent une source d'inspiration. Celle-ci peut être issue de la modélisation des systèmes complexes naturels. Il s'agit de copier et d'adapter les concepts mis en œuvre par le monde des vivants pour la résolution de problèmes.

La source d'inspiration que constitue la biologie a de plus en plus de succès dans une branche de l'intelligence artificielle que l'on peut nommer informatique biomimétique.

Le principe de base de cette méthode de développement suit les étapes représentées sur le schéma de la figure 3.1 :

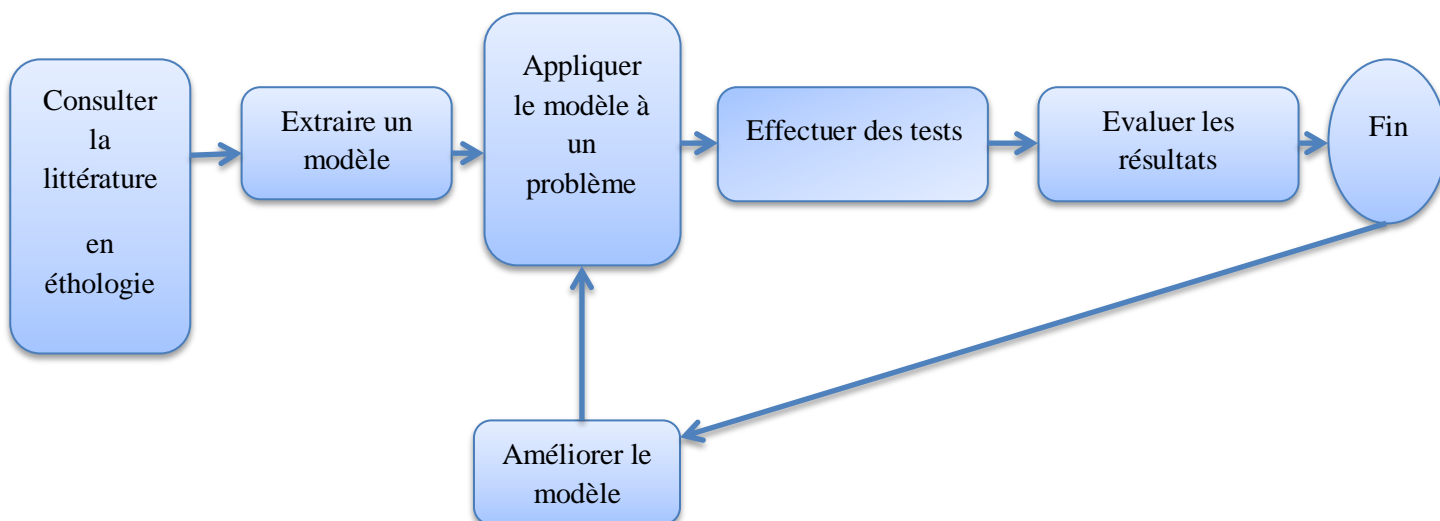


Figure 35 : Principe de développement d'une méthode d'optimisation

III.2. Méta-heuristiques pour la segmentation

Le problème de segmentation est considéré comme un problème d'optimisation. Sa résolution consiste à explorer un espace de recherche afin de maximiser (minimiser) une fonction donnée. Les complexités en taille et en structure relatives à l'espace de recherche et à la fonction à maximiser conduisent à utiliser des méthodes de résolution radicalement différentes. En première approximation, on peut dire qu'une méthode déterministe est adaptée à un espace de recherche stochastique.

En pratique, l'objectif n'est pas d'obtenir un optimum absolu, mais seulement une bonne solution sensiblement meilleure.

Pour atteindre cet objectif au bout d'un temps de calcul raisonnable, il est nécessaire d'avoir recours à des méthodes appelées "*heuristiques*". La plupart d'entre elles sont conçues spécifiquement pour un type de problème donné.

D'autres, au contraire, désormais appelées "*méta-heuristiques*", sont capables de s'adapter à différents types de problèmes.

Ces méthodes ont en commun les caractéristiques suivantes :

- ✓ Elles sont, au moins pour partie, stochastiques : cette approche permet de faire face à l'explosion combinatoire de possibilités ;
- ✓ Elles sont inspirées par des analogies : avec la physique (recuit simulé, diffusion simulée,...), avec la biologie (algorithmes évolutionnaires, recherche tabou,...) ou avec l'éthologie (colonies de fourmis,...)
- ✓ Elles partagent aussi les mêmes inconvénients : les difficultés de réglage des paramètres de la méthode, et le temps de calcul élevé ;

Il existe dans la littérature plusieurs méta-heuristiques qui peuvent être classées comme suit :

- Méta-heuristiques à solution unique ;
- Méta-heuristiques à base de population.

III.2.1. Méta-heuristiques à solution unique

Les méthodes itératives à solution unique ou méta-heuristique à base de voisinage s'appuient toutes sur un même principe. A partir d'une solution unique considérée comme point de départ, la recherche consiste à passer d'une solution à une solution voisine par déplacements successifs. Ainsi, l'ensemble des solutions que l'on peut atteindre à partir d'une solution est appelé voisinage de cette solution.

La détermination d'une solution voisine dépend du problème traité : d'une manière générale, les opérateurs de recherche locale s'arrêtent quand une solution est dans le voisinage. Mais accepter seulement ce type de solution n'est bien sûr pas satisfaisant. C'est pour cela, qu'il serait donc intéressant de pouvoir s'échapper de ces minimaux locaux. Il faut alors permettre à l'opérateur de faire des mouvements pour lesquels la nouvelle solution retenue sera de qualité moindre que la précédente.

Parmi ces méthodes, on trouve : le recuit simulé et la recherche tabou.

III.2.2. Méta-heuristiques à base de population

Les méthodes de recherche à population, comme leur nom l'indique, travaille sur une population de solutions et non pas sur une solution unique. On peut trouver d'autres noms génériques pour ces méthodes, le plus en vogue étant sans doute *evolutionary algorithms*.

Le principe général de toutes ces méthodes consiste à combiner des solutions entre elles pour en former de nouvelles en essayant d'hériter des "bonnes" caractéristiques des solutions parents.

Un tel processus est répété jusqu'à ce qu'un critère d'arrêt soit satisfait (nombre de générations maximum, nombre de générations sans améliorations, temps maximum, borne atteinte,...etc.). Donc, les méthodes d'optimisation à population améliorent la solution, au fur et à mesure des itérations, leur intérêt est d'utiliser la population comme facteur de diversité.

III.3. Méta-heuristiques à population en segmentation

Dans cette partie, nous allons décrire brièvement les méta-heuristiques appliquées au problème de la segmentation d'images. L'ouvrage de Siary [16] consacré à l'application des méta-heuristiques et traitement d'images en général, montrent l'importance de ces méthodes dans cette discipline.

Plusieurs systèmes complexes naturels ont été l'objet d'inspiration et de modélisation informatique capable de résoudre plusieurs problèmes notamment celui de la segmentation, la figure suivante illustre les différentes méta-heuristiques qui sont utilisées à ce jour dans la littérature pour la segmentation d'images :

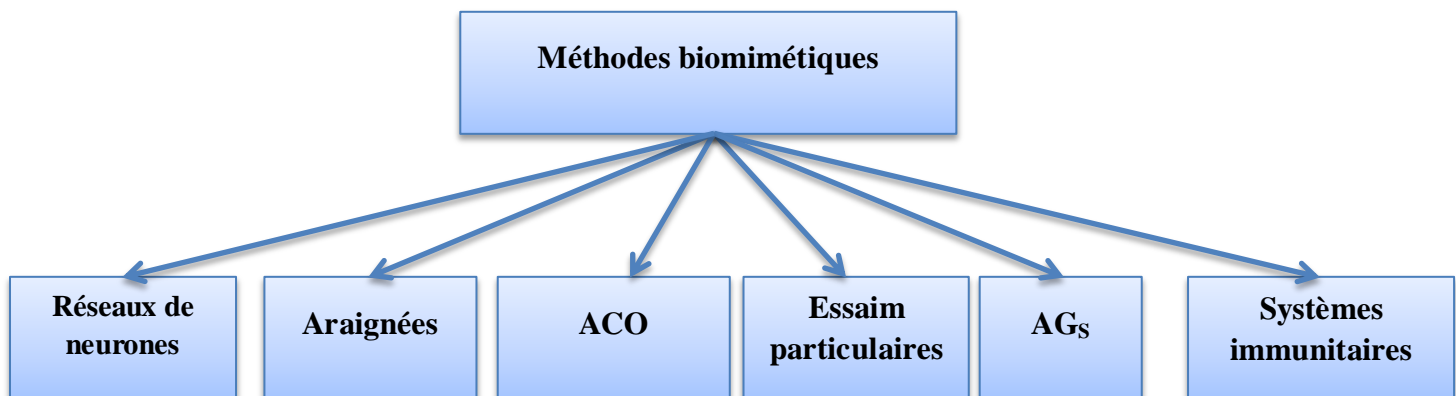


Figure 36 : Méthodes biomimétiques pour la segmentation [2]

III.3.1. Algorithmes génétiques

L'application des algorithmes génétiques à la segmentation d'images a commencé dans les années quatre-vingt-dix. A titre d'exemple, on peut citer la thèse de Andrey [17] et l'ouvrage de Bhanu et al [18] qui sont entièrement dédiés à ce sujet.

Le principe de ces algorithmes est conçu sur des méthodes, basées sur les mécanismes biologiques tels que les lois de Mendel et sur le principe fondamental de Charles Darwin.

Holland a exposé les principes de ces algorithmes pour permettre aux ordinateurs "d'imiter les êtres vivants en évoluant" pour rechercher la solution à un problème [19].

Il a expliqué d'abord comment ajouter de l'intelligence dans un programme informatique avec les croisements (échange du matériel génétique) et la mutation –source de

la diversité génétique). Il a ensuite formalisé les principes fondamentaux des algorithmes génétiques :

- ✓ La capacité de représentation élémentaire, comme les chaînes de bits, à coder des structures complexes ;
- ✓ Le pouvoir de transformation élémentaire à améliorer de telles structures ;

Plus récemment, les algorithmes génétiques ont été enrichis par Goldberg [20] en s'appuyant sur le parallèle suivant :

- ✓ Un individu est lié à un environnement par son code d'ADN ;
- ✓ Une solution est liée à un point par son indice de qualité ;
- ✓ Une « bonne » solution à un problème donné peut être vue comme un individu susceptible de survivre dans un environnement donné.


Le tableau 3.1 présente les différentes étapes de base d'un algorithme génétique.

Dans cet exemple, ' $P(t)$ ' représente une *population de solutions candidates* pour un problème donné, à l'itération t .

1. Initialisation de $P(t)$;
 2. Evaluer chaque individu de $P(t)$;
 3. Tant que le critère d'arrêt n'est pas satisfait Faire
 - $t = t + 1$
 - Sélectionner $P(t+1)$ de $P(t)$
 - Croisement $P(t+1)$
 - Muter $P(t+1)$
 - Evaluer $P(t+1)$
- Fin Tant que
4. Afficher le meilleur état rencontré au cours de la recherche

Table 3 : Principe d'un algorithme génétique [10]

La figure suivante illustre la carte contours obtenue en appliquant un Algorithme génétique par P. Andrey (1997) [21]:



(a) Image originale

(b) contours détectés par un algorithme génétique

Figure 37 : Contours détectés par un algorithme génétique [21]

III.3.2. Essaim particulaire (EP)

La méthode des essaims particulaire (« Particle Swarm Optimization », PSO a été développée en 1995 [22]. Son principe provient des comportements collectifs d'animaux. Elle s'identifie aux algorithmes génétiques, car elle ne possède pas d'opérateur d'évolution mais une population de solutions potentielles est utilisée dans la recherche.

L'algorithme commence avec une initialisation aléatoire de l'essaim de particules dans l'espace de recherche. Puis, chaque particule est modélisée par sa position dans l'espace de recherche et par sa vitesse. Donc, à chaque instant, toutes les particules ajustent leurs positions et vitesses, c'est-à-dire leur trajectoire, par rapport à :

- ✓ Leurs meilleures positions ;
- ✓ La particule ayant la meilleure position dans l'essaim ;
- ✓ Leurs positions actuelles.

En réalité, chaque particule est influencée, non seulement par son propre expérience, mais aussi par celle des autres particules.

La position et la vitesse d'une particule dans un espace de recherche à N dimensions sont définies par [10] : $P_i = p_{i,1}, \dots, p_{i,N}$ et $V_i = v_{i,1}, \dots, v_{i,N}$ respectivement

Chaque particule est caractérisée par sa meilleure position $L_i = l_{i,1}, \dots, l_{i,N}$ à l'itération t.

La meilleure position qu'atteint l'essaim est sauvegardée dans le vecteur $G = g_1, \dots, g_N$.

La vitesse de chaque particule est mise à jour selon l'expression suivante :

$$V_{i,j} = K [w * v_{i,j}(t) + c_1 * r_1 * (I_{i,j} - v_{i,j}(t)) + c_2 * r_2 * (g_j - v_{i,j}(t))] \quad (3.1)$$

$$\text{Avec } K = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|} \quad \varphi = c_1 + c_2 \text{ et } \varphi > 4 \quad (3.2.)$$

W : une constante appelée facteur d'inertie qui contrôle l'influence de l'ancienne vitesse sur la vitesse courante, afin de permettre aux particules d'éviter les minimax locaux.

c_1 et c_2 des constantes appelées coefficient d'accélération, c_1 contrôle le comportement de la particule dans sa recherche autour de sa meilleure position et c_2 contrôle l'influence de l'essaim sur le comportement de la particule.

r_1 et r_2 des nombres aléatoires uniformément distribués dans l'intervalle $[0, 1]$;

La position à l'itération $t+1$ est alors :

$$P_{i,j}(t+1) = p_{i,j}(t) + v_{i,j}(t+1) \quad \text{pour } j=1, \dots, N \quad (3.3)$$

Les étapes de l'algorithme d'essaim particulaire sont données dans le tableau suivant :


1. Initialisation la population de particules avec des positions et vitesses aléatoires
2. Evaluer la fonction objective pour chaque particule et calculer g
3. Pour chaque individu i , L_i est initialisée à P_i
4. Répéter jusqu'au critère d'arrêt
 - Mettre à jour les vitesses et les positions des particules
 - Evaluer la fonction objective pour chaque individu
 - Calculer les nouveaux g et L_i
5. Afficher le meilleur état rencontré au cours de la recherche

Table 4 : Principe de l'algorithme d'essaim particulaire

La figure suivante illustre la carte contours obtenue en appliquant d'un algorithme d'optimisation pas Essaim particulaire :



(a) Image originale



(b) Détection de contours par les particules

Figure 38 : Extraction de contours effectuée par Essaim Particulaire [23]

III.3.3. Araignées sociales

Les araignées sociales est un autre modèle social biologique, et une source d'inspiration pour la résolution collective des problèmes. Ce modèle concerne la construction collective de toile.

L'hypothèse des biologistes est que les araignées sociales présentent des processus stigmergiques qui désignent que le comportement d'un individu est influencé par le résultat des actions passées des autres individus.

Au fait, les araignées effectuent collectivement des activités particulièrement impressionnantes : construction collective, prise de décision collective lors du transport de proie, synchronisation et coordination lors de la prédation.

Le modèle comportemental qui définit le comportement et la construction des araignées et qui a été utilisé pour les simulations informatiques est :

- ✓ L'environnement

Il s'agit d'une grille carrée où chaque case correspond à un piquet, ceux-ci pouvant être de hauteurs différentes. Ils peuvent être reliés entre eux par des fils de soie toujours fixés en leur sommet.

Dans le cas des images, l'environnement est un carré de $N*N$ piquets dans lequel évoluent les araignées. Un piquet correspond à un ou plusieurs pixels de l'image d'origine. La hauteur d'un piquet correspond au niveau de gris du ou des pixels correspondants. Il peut donc y avoir 256 hauteurs différentes. Initialement, il n'y a pas de fils dans l'environnement, ils apparaîtront au fur et à mesure du déplacement des araignées.

✓ Les agents et leur comportement

Les agents correspondent aux araignées, ils sont décrits par deux items comportementaux : le déplacement et la pose d'un fil d'une manière aléatoire. Lorsque le fil est fixé, il correspond au plus court segment entre le dernier piquet de pose et celui courant. Pour se déplacer à partir d'un piquet donné, une araignée a trois choix possibles :

1. Aller sur un piquet adjacent ;
2. Aller sur un piquet en suivant un fil qu'elle a elle-même tissé ;
3. Aller sur un piquet en suivant un fil tissé par l'une de ces congénères


Pour chacun de ces choix, une pondération sera associée : constante en ce qui concerne les piquets adjacents, paramétrée pour les deux derniers choix par respectivement le coefficient d'attraction pour sa soie et le coefficient d'attraction pour la soie des autres.

Chaque piquet accessible est alors pondéré relativement aux manières d'y accéder, ce poids une fois normalisée fournit la probabilité pour l'araignée d'accéder à cette case.

✓ La dynamique du système

Elle est construite sur un principe stigmergique : les comportements des agents ont des effets sur l'environnement (pose des fils), en retour le comportement est influencé par le contexte de l'agent : plus il y a de fils vers une position donnée, plus cette position a des chances d'être choisie. Ainsi, les agents sont piégés par leur soie relativement à l'attraction qu'elle exerce. En termes de résultat, la toile devient alors l'agrégation des piquets ayant une propriété commune relative à la hauteur du piquet [24].

Les résultats de l'application des araignées sont illustrés par les figures suivantes :



(a) Image originale (b) régions résultant de (c) les densités correspondantes

La simulation de tissage de toile [24]

Figure 39 : Extraction de contours par araignées sociales

III.3.4. Réseaux de neurones

Les réseaux de neurones sont définis comme des modèles théoriques de traitement de l'information inspirés des observations relatives au fonctionnement des neurones biologiques et du cortex cérébral. Ceci est illustré par la figure suivante :

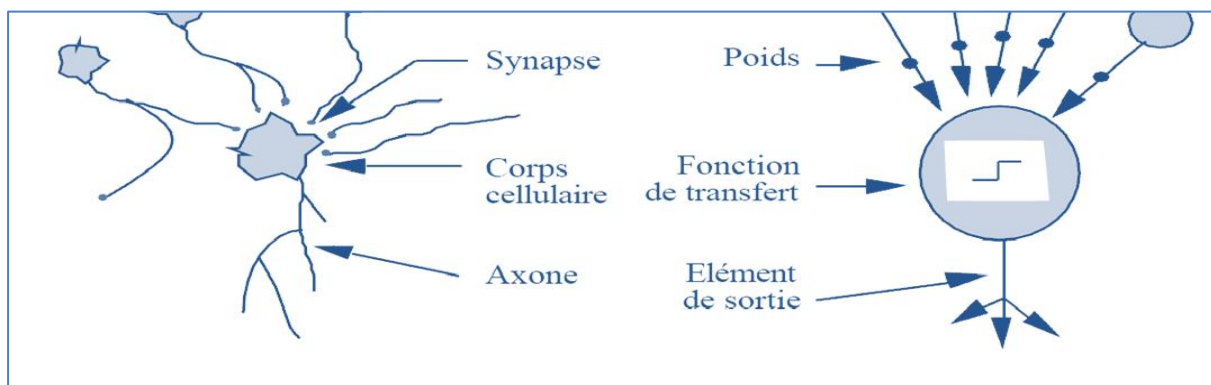


Figure 40 : Mise en correspondance entre neurone biologique-artificiel

Par analogie aux neurones biologiques, les neurones artificiels ont pour but de reproduire des raisonnements « intelligents » d'une manière artificielle. Ces neurones peuvent adapter certaines qualités habituellement propres au biologique, c'est-à-dire, la généralisation, l'évolutivité, et une certaine forme de déduction.

Un réseau de neurones est composé généralement d'un grand nombre d'unités de calcul très simple appelés neurones formels qui sont interconnectés entre eux, de sorte que les signaux sortant (output) des neurones deviennent des signaux entrants (input) dans d'autres neurones [25].

Chaque neurone artificiel est un automate binaire à deux états « actif » et « inactif ». Il reçoit un nombre visuel de signaux 'x' en provenance d'autres neurones. A chacun de ces signaux est associé un poids « w » représentatif de la force de la connexion

Ceci est illustré par la figure suivante :

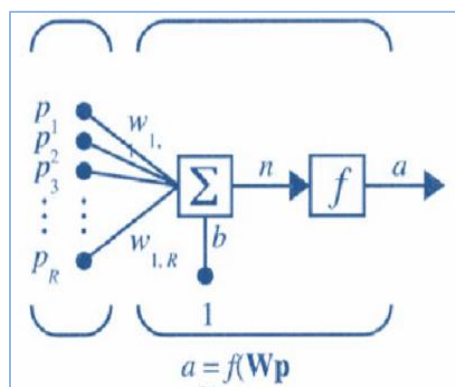


Figure 41 : Neurone formel

Le neurone change d'état suivant que la somme des connexions pondérées dépasse ou non un seuil d'activation "θ", les fonctions d'activation sont illustrées par la figure suivante :





Figure 42 : Quelques fonctions d'activation

Un neurone artificiel est caractérisé par sa topologie illustrée dans la (figure 43) et cinq paramètres qui sont :

1. La nature des entrées (booléennes ou réelles) ;
2. La fonction d'entrée totale, définissant le prétraitement effectué sur les entrées ;
3. La fonction de seuillage (activation) du neurone définissant son état interne en fonction de la somme pondérée de ses entrées ;
4. La fonction de sortie calculant la sortie du neurone en fonction de son état d'activation ;
5. La nature des sorties du neurone.




(a) Réseau complètement connecté

(b) Réseau en boucle, complètement connecté

Figure 43 : Quelques topologies de réseaux de neurones

Les cellules d'entrée du réseau correspondent chacune à un attribut des pixels (réduit au niveau de gris la plupart du temps). Par contre les cellules de sortie donnent la classe du pixel.

La figure suivante illustre un exemple de segmentation par réseaux de neurones :



(a) Image originale

(b) contours détectés par ondelettes

(c) contours détectés par ondelettes et neurones

Figure 44 : Détection de contours par ondelettes et réseaux de neurones [26]

III.3.5. Systèmes immunitaires

Le système immunitaire est un processus de l'immunologie composé d'organes, de cellules et de molécules qui assure le maintien de l'intégrité de l'organisme qu'il défend.

Cette défense repose sur des concepts tels que la mémoire, la reconnaissance du « *soi qui correspond à l'individualité biologique d'un être vivant* », l'apprentissage, l'autorisation, la coopération et la spécificité.

La présence du « *non soit qui correspond donc à tout corps étranger* » au sein de l'organisme entraîne une ou plusieurs réponses du système immunitaire spécifiquement dirigées contre l'intrus. Il peut aussi éliminer les cellules du « soi » qui sont potentiellement dangereuses comme les cellules cancéreuses [2].

Ces systèmes sont modélisés pour être appliqués à différents problèmes dans l'intelligence artificielle, plus précisément à la classification de donnée.

Le réseau des systèmes immunitaires (AiNet) est un algorithme de classification inspiré du fonctionnement du système immunitaire des vertèbres. Les données à classifier sont vues comme des antigènes qui stimulent le répertoire des anticorps. Chaque anticorps réagit à la stimulation de façons différentes en fonction de son degré de similarité avec l'antigène.

Les anticorps présentant une bonne correspondance auront tendance à se multiplier alors que les anticorps n'ayant pas réagi à un antigène depuis un certain temps auront tendance à disparaître : c'est le principe de la *sélection par clonage*.

Le répertoire des anticorps subit des mutations dirigées afin de pouvoir mieux répondre aux simulations futures : c'est le principe de la *maturation d'affinité*.

Plus la correspondance entre le gène et l'anticorps est grande, plus la mutation sera importante et inversement.

Afin de limiter la redondance dans le répertoire d'anticorps, une opération d'élimination aura lieu lorsque deux anticorps se ressemblent suffisamment : l'un des deux sera éliminé. Et enfin, le répertoire des anticorps résultant servira de déduire la classification résultante.

On peut résumer les mécanismes des systèmes immunitaires dans ce qui suit :

- ✓ **La reconnaissance de la forme de l'antigène** : qui est effectuée par des récepteurs, sur la surface des anticorps libérés par les cellules immunitaires. Pour lier un antigène aux différents anticorps il faut que leurs structures aient des formes complémentaires. La force de cette liaison dépend de l'affinité entre antigène et anticorps.
- ✓ **La réponse immunitaire** : elle est constituée par une réponse immédiate à l'attaque de l'antigène d'une part, puis une réponse adaptative d'autre part, spécifique à l'antigène et liée au processus de maturation d'affinité.
- ✓ **La sélection clonale** : quand les anticorps se lient à l'antigène, la cellule immunitaire s'active et commence à proliférer. De nouvelles cellules seront ensuite produites, copies conformes de la cellule parente, et spécifiques à l'antigène envahissant.
- ✓ **La maturité d'affinité** : garantie que le système immunitaire devient de plus en plus efficace face aux attaques des antigènes.

La figure suivante montre les résultats obtenus après application des systèmes humanitaires pour segmenter des images :



(a) Image originale (b) segmentation étalon (c) segmentation avec système immunitaire

Figure 45 : Détection de contours par système immunitaire [27]

III.3.6. Colonies de fourmis artificielles

Les fourmis comme d'autres insectes telles que les termites, les araignées et certaines espèces d'abeilles et de guêpes, constituent aussi des sources d'inspiration pour le développement de systèmes artificiels.

L'exemple des fourmis est le plus répandu dans la littérature grâce à leur capacité à réaliser des tâches hautement complexes à partir d'interactions d'insectes simples à l'intelligence très rudimentaire.

En particulier deux comportements collectifs ont été principalement étudiés chez les fourmis : l'optimisation de chemin ou fourragement et le tri des éléments du couvain.

Le fourragement : ce comportement met en évidence la capacité des fourmis à optimiser la procédure de fourragement.

En effet, au départ les fourmis se déplacent d'une manière aléatoire de la fourmilière vers une source de nourriture en laissant les traces de phéromones sur le chemin qu'elles empruntent.

Cette trace tend à attirer les congénères qui, en la suivant, vont parvenir à la nourriture. Il a été constaté alors que les fourmis qui choisissent l'itinéraire le plus court, le terminent le plus vite. Les fourmis vont alors préférer progressivement cet itinéraire car il est marqué avec une plus grande quantité de phéromones. Ce comportement a été largement développé et appliqué à de nombreux problèmes d'optimisation combinatoire et numérique.

Le tri des éléments du couvain : ce comportement collectif concerne l'aptitude des fourmis à nettoyer leur nid en organisant collectivement des cimetières composés de cadavres empilés les uns sur les autres. Le principe est le suivant : plus un cadavre est isolé, plus la fourmi a de chances à le ramasser. La probabilité pour une fourmi porteuse de déposer ce qu'elle transporte suit une règle inverse : plus le monticule observé est important plus la probabilité de déposer le corps au sol sera grande. Ce comportement peut être directement mis en relation avec le problème de la classification [25].

Notre application se base entièrement sur les fourmis artificielles pour la détection des contours des images à niveaux de gris, pour cela cette technique sera détaillée dans le prochain chapitre.

Les figures suivantes montrent la détection des contours par les fourmis artificielles :



(a) image originale

(b) contours détectés par les fourmis artificielles

Figure 46 : Détection de contours par les colonies de fourmis artificielles [28]

III.4. Discussion

Comme nouvelles sources d'inspiration des nombreuses méta-heuristiques, la nature et la biologie prennent place. Ainsi, les théories de l'évolution et les phénomènes observés dans les systèmes naturels ont permis l'élaboration d'algorithmes applicables pour tous les problèmes d'optimisation.

Dans le cadre de notre travail, on s'intéresse particulièrement, à l'optimisation de la segmentation par une méthode à population qui consiste en colonies de fourmis artificielles, cette technique a prouvé son succès dans plusieurs problèmes de divers domaines comme : application dans la recherche (le problème de voyageurs de commerce,...), applications industrielles (tests des applications), etc.

Dans les sections suivantes seront traitées en détail la technique de l'Optimisation par Colonies de Fourmis artificielles (OCF) adaptée pour segmenter des images en contours.

Chapitre IV

Optimisation de la segmentation par Colonies de Fourmis Artificielles

IV.1. Préambule

La nature montre que les petites créatures comme les fourmis arrivent à résoudre collectivement des problèmes quotidiens nombreux et trop complexes pour une seule fourmi tels que : recherche de nourriture, construction de nid, division du travail et allocation des tâches entre les individus, avec une organisation extrêmement structurée et sans aucune supervision.

Par les comportements simples de chacune des fourmis, des interactions limitées à travers une coopération inconsciente, émergent des comportements collectifs intelligents et des modèles d'auto-organisation.

Deux comportements collectifs ont été principalement étudiés chez les fourmis :

➤ L'optimisation de chemin

Ce comportement est appelé aussi fourragement, permet aux fourmis de retrouver le plus court chemin entre leur nid et une source de nourriture grâce à un système de marquage de phéromones. Ce comportement naturel a été modélisé et transposé à la résolution de nombreux problèmes, il est connu sous le nom d'une nouvelle méta-heuristique.

➤ La classification de couvains

Ce comportement collectif des fourmis concerne la capacité des fourmis à organiser les couvains collectivement, l'exemple le plus remarqué c'est la création de cimetières différents composés de cadavres empilés les uns sur les autres. Là aussi, les chercheurs ont exploité ce comportement pour fournir des algorithmes de classification pour lesquels l'informatique classique n'a pas donné de solution satisfaisante.

IV.2. Fourmis réelles

Les fourmis font partie de la famille de formicidés, incluse dans l'ordre des Hyménoptères, c'est-à-dire des insectes dont les deux paires d'ailes sont membraneuses et fines. Les fourmis sont réparties en 11 sous-familles, et approximativement plus de 12000 espèces.

La fourmi peut mesurer de quelques millimètres à plusieurs centimètres de long [25].

IV.2.1. Anatomie d'une fourmi

Le corps d'une fourmi réelle se compose de trois parties principales : la tête, le thorax et l'abdomen.

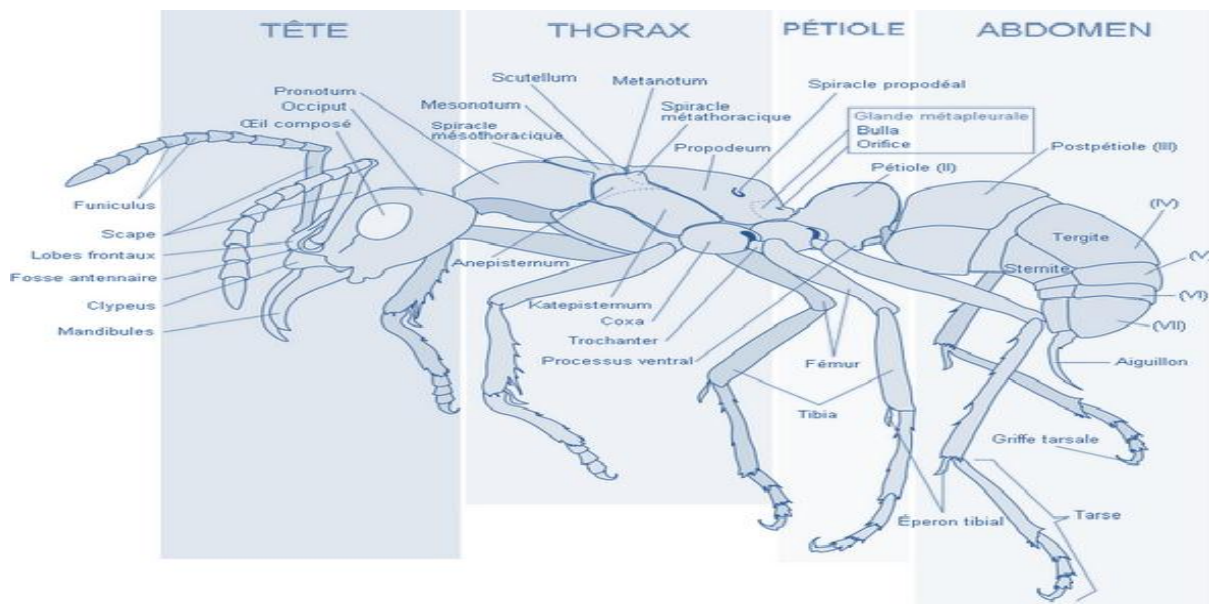


Figure 47 : Anatomie d'une fourmi

➤ La tête

Elle est ornée d'une paire d'antennes qui abritent plusieurs organes des sens : le toucher, l'odorat et le goût. On trouve également à l'extrémité de la tête, la bouche qui sert à la fois à l'alimentation et très souvent d'outil de saisie. Les yeux, au nombre de deux, sont composés et formés d'une multitude de facettes. Quelques fourmis sont complètement aveugles, sans aucun organe visuel.

➤ **Le thorax**

Appelé aussi corselet, porte trois pattes, très longues et terminées par deux griffes. Les organes tactiles sont bien développés et sont constitués par des poils répartis sur tout le corps. Leur densité est plus forte sur les antennes et aux extrémités des pattes.

➤ **L'abdomen**

Elle est reliée au thorax par un étroit pédoncule ou pétiole. Elle renferme le jabot social, l'estomac, l'intestin et les conduits respiratoires, et chez les reines et les mâles, l'appareil reproducteur.

IV.2.2. Communication entre fourmis

Les communications interindividuelles entre fourmis sont de plusieurs types et varient d'une espèce à l'autre. Les principaux moyens de communication sont :

✓ **La communication tactile**

Pour qu'elles puissent se reconnaître comme membres de la même fourmilière, lorsque deux fourmis se rencontrent, elles procèdent à quelques attouchements d'antennes ou de pattes.

✓ **La communication sonore**

Les fourmis utilisent des stimuli vibratoires comme moyens de communication en frappant les parois de la fourmilière avec leur abdomen pour prévenir les autres. Elles tapotent aussi leurs antennes pour se parler. Elles utilisent ce signal comme signal de détresse en cas de danger, de qualité, de demande d'aide en cas où la nourriture trouvées est de grande taille.

✓ **La communication visuelle**

Elle permet aux fourmis de retrouver leur chemin, guidées par des marqueurs visuels.

✓ **La communication chimique**

Les fourmis sont équipées de glandes produisant des phéromones, substances chimiques volatiles et odorantes qu'elles peuvent sentir par leurs antennes. Ce signal chimique porte l'information à la fois sur l'espèce, la société mais aussi la caste et le stade de développement auxquelles appartiennent les fourmis rencontrées.

C'est en sécrétant cette substance qu'une fourmi éclairieuse marque le chemin qu'elle a utilisé et revient avertir ses pairs de la présence de nourriture ou d'un danger, ainsi que de sa localisation. C'est le moyen de communication le plus efficace et le plus utilisé par toutes les espèces de fourmis.

IV.3. Fourmis artificielles

C'est une entité simple dotée d'un comportement similaire ou étendu à celui de la fourmi réelle. Ce comportement doit être élémentaire, restreint et donc facile à programmer. A l'intérieur d'une colonie, les fourmis sont concurrentes et asynchrones, elles coopèrent inconsciemment ensemble pour la résolution du problème considéré. Les fourmis artificielles communiquent entre elles indirectement par stigmergie via des modifications de leur environnement (par exemple par dépôt de traces de phéromones artificielle) qui représente la mémoire collective de la colonie. Elles ont été de plus enrichies des contraintes et de comportements qu'on ne trouve pas dans leurs congénères réelles mais qui sont spécifiques au problème qu'elles résolvent.

IV.4. Fourmis réelles/ Fourmis artificielles


| | Fourmis réelles | Fourmis artificielles |
|-----------------------|------------------------------------|---|
| Depuis quand ? | 100 * 10 ⁶ années | 15 à 20 ans |
| Où ? | Tout écosystème terrestre | Ordinateurs, réseaux, robots,... |
| Combien ? | 10 ¹⁸ |  |
| Qui ? | Entomologistes, myrmécologues | Informaticiens,... |
| Pourquoi ? | Equilibres, régulations, évolution | optimisation |

Table 5 : Comparaison entre les fourmis réelles et artificielles [29]

IV.5. De fourmis réelles aux fourmis artificielles

Les fourmis sont caractérisées d'une capacité naturelle à résoudre différents problèmes liés à leur survie, qui est simulée et transposée pour la résolution de différents problèmes notamment le fourragement et le tri ou la classification de cadavres.

Les premiers travaux dans ce sens ont simulé ces comportements collectifs observés chez les fourmis réelles et l'ont appliqué pour traiter différents problèmes comme l'optimisation de distance et classification de couvains.

IV.5.1. Optimisation du chemin

Le problème du voyageur de commerce été le premier problème pour lequel les chercheurs ont appliqué le comportement des fourmis pour optimiser le chemin dans la recherche de la nourriture. Ainsi, les bons résultats obtenus ont incité de nouveaux chercheurs à l'utiliser dans d'autres domaines notamment la segmentation d'images en lui ajoutant certaines extensions que nous allons exposer dans la suite.

IV.5.1.1. Expériences pratiques

Pour bien comprendre le comportement naturel des fourmis dans le fourragement, des expériences différentes ont été effectuées :

a) Pont binaire

Dans cette expérience, le nid des fourmis et la source de nourriture sont séparés par un pont binaire constitué de deux branches identiques.

Au départ, il n'y a pas de phéromone sur le pont. Donc, chaque branche peut être choisie par une fourmi avec la même probabilité [30]. Néanmoins, après une certaine période, on en déduit que plus les fourmis suivent un chemin, plus elles déposent de phéromones, plus ce chemin devient intéressant à suivre. Ainsi la probabilité avec laquelle une fourmi choisit un chemin, augmente avec le nombre de fourmis qui ont pris ce chemin précédemment.




Figure 48 : Pont binaire de Deneubourg

b) Pont binaire à longueurs inégales

Dans cette expérience, les chercheurs ont étudié l'effet de l'utilisation d'un pont avec des longueurs inégales. En raison du même mécanisme de dépôt de phéromone, les fourmis qui ont pris la branche la plus courte arrivent à la source de nourriture en premier, et retournent le long du même chemin en premier au nid, en augmentant ainsi, les quantités de phéromones sur ce plus court chemin, renforçant ainsi le choix des autres fourmis [30].




Figure 49 : Expérience du pont avec des branches de tailles différentes

c) Pont avec un obstacle

Dans cette expérience, pendant que les fourmis suivent leur chemin (**Figure 50 (a)**), un obstacle est placé afin de leur barrer la route entre le nid et la nourriture (**Figure 50 (b)**).

Les fourmis doivent alors contourner cet obstacle par la droite ou par la gauche afin de poursuivre leur chemin. Comme initialement, il n'y a aucune trace de phéromone le long de l'obstacle, la moitié des fourmis passent par le côté droit et l'autre moitié par le côté gauche (**Figure 50 (b)**). Mais après un certain temps, les chercheurs ont observé que les fourmis qui

ont choisi le chemin le plus court, parviennent à reconstituer plus rapidement la concentration en phéromones sur ce chemin que celles qui ont choisi le chemin le plus long (**Figure 50 (c)**).

Ainsi, la concentration de phéromones sur ce plus court chemin va augmenter, incitant ainsi d'autres fourmis à le choisir (**Figure 50 (c)**) [30].




Figure 50 : Effet de dépôt d'un obstacle entre la source de nourriture et le nid

IV.5.1.2. La méta-heuristique par les fourmis artificielles

Les travaux de Deneubourg et Marco Dorigo furent les premiers à modéliser le comportement de fourrageage et à l'appliquer pour résoudre un problème d'optimisation classique : le problème du voyageur de commerce ([31], [32]).

Cette première modélisation s'est depuis très popularisée et a donné naissance à de nouveaux algorithmes appliqués à d'autres types de problèmes pour lesquels il est difficile de trouver une solution exacte.

Ces différents algorithmes ont été regroupés dans le terme général de « méta-heuristique par les colonies de fourmis » ou « Ant Colony Optimisation (ACO) ».

Dans l'OCF, le voisinage du nid des fourmis est associé à l'espace des solutions, telle que chaque solution s'apparente à une source de nourriture dont la qualité est fournie par une fonction objectif.

Chaque fourmi est assimilée à un processus stochastique de construction de solutions itératives. La construction est biaisée par une phéromone artificielle et une information heuristique propre au problème à résoudre.

Les traces de phéromones sont typiquement, la mémoire des fourmis sur les éléments de la solution, et sont régulièrement mise à jour par les processus de construction et par un mécanisme simulant l'évaporation de la phéromone [33].

L'organisation de la méta-heuristique est basée sur les règles régissant le comportement des fourmis et un autre processus concernant l'évaporation des pistes de phéromones.

a) Phéromones et mémoires

Le choix de la méthode d'implémentation des pistes de phéromone est important pour obtenir les meilleurs résultats. Ce choix est lié aux possibilités de représentation de l'espace de recherche, qui peuvent apporter des façons différentes d'implémenter les pistes.

En effet, les pistes de phéromone décrivent à chaque pas l'état de la recherche de la solution par le système, les agents modifient la façon dont le problème va être représenté et perçu par les autres agents.

Cette information est partagée par le biais des modifications de l'environnement des fourmis, par une forme de communication indirecte : la stigmergie.

L'information est stockée un certain temps dans le système, ce qui peut être considéré comme une forme de mémoire efficace consiste à utiliser une piste $\tau_{i,j}$ entre deux villes « i » et « j » comme une représentation de l'intérêt de visiter la ville « i » après la ville « j ».

b) Intensification/Diversification

Le problème de l'emploi relatif de processus de diversification et d'intensification est un problème extrêmement courant dans la conception et l'utilisation de méta-heuristique.

Par l'intensification, on entend l'exploitation de l'information rassemblée par le système à un moment donné. La diversification est au contraire l'exploration de régions de l'espace de recherche imparfaitement prises en compte.

Il va s'agir donc, de choisir où et quand « injecter de l'aléatoire » dans le système (diversification) et/ou améliorer une solution (intensification).

c) Etat de l'art de l'OCF

D'une manière générale, l'utilisation de l'OCF nécessite de choisir une représentation formelle du problème d'optimisation à traiter et de définir le processus de construction de solutions par les fourmis en utilisant cette représentation.

L'OCF présente les caractéristiques suivantes :

- Il est flexible : il peut être facilement réutilisable pour des versions modifiées d'un même problème ;
- Il est robuste et nécessite peu de changement pour leur application à de nouveaux problèmes d'optimisation combinatoires ;
- Il est une approche basée population : ce qui permet d'exploiter le caractère auto catalytique de la méthode en tant que mécanisme de recherche. D'un autre côté, une implémentation parallèle de la méthode est naturelle.

IV.5.2. Classification

De la même façon que les algorithmes regroupés sous la catégorie de l'optimisation par colonie de fourmis (OCF), qui s'inspire de la stratégie de recherche de nourriture chez les fourmis, la classification par fourmis artificielles s'inspire du tri collectif de couvains ou la construction de cimetières.

Les premiers travaux réalisés dans ce domaine ont été ceux de Deneubourg et son équipe [30]. La classification par fourmis artificielles se base sur un ensemble d'automates, se déplaçant aléatoirement sur une grille rectangulaire et qui sont capables de ramasser et déposer des objets sur cette grille, dans le but d'obtenir une classification des objets selon un critère donné :

Le modèle de règles utilisé est relativement simple :

- Lorsqu'une fourmi rencontre un élément du couvain, la probabilité qu'elle s'en empare est d'autant plus grande que cet élément est isolé ;
- Lorsqu'une fourmi transporte un élément du couvain, elle le dépose avec une probabilité d'autant plus grande que la densité d'élément du même type dans le voisinage est grande.

On définit les probabilités de ramasser un objet par (Pp) et les probabilités de le déposer (Pd)

Lorsqu'une fourmi ne transporte aucun élément, sa probabilité d'en ramasser un, qu'elle rencontre sur son chemin, est donnée par :

$$Pp = \left(\frac{k_1}{k_1 + f} \right)^2 \quad (IV.1)$$

k_1 : une constante positive et f correspond à la proportion d'éléments perçus dans le voisinage de la fourmi.

Quand il y a peu d'objets dans le voisinage de l'objet convoité par la fourmi, $f \ll k_1$ ce qui signifie que Pp est proche de 1 et l'objet a beaucoup de chance d'être ramassé. Inversement, quand le voisinage est dense en élément, $f \gg k_1$, alors Pp est proche de 0.

Lorsqu'une fourmi chargée d'un objet se déplace, sa probabilité de le déposer est donnée par :

$$Pd = \left(\frac{f}{k_2 + f} \right)^2 \quad (IV.2)$$

k_2 : une constante positive et f correspond au nombre d'objets rencontrés durant les 't' derniers déplacements divisé par le nombre maximum d'objets qui auraient pu être rencontrés.

Les résultats obtenus par simulation montrent l'apparition de groupes d'objets, les agents ainsi définis permettent donc de ranger une surface sur laquelle des objets ont été éparpillés. De ce fait, de nombreux algorithmes portant sur la classification des objets avec des fourmis artificielles ont été développés.

IV.6. Segmentation d'images en contours par l'OCF

La détection de contours d'une image est un processus dont le but est d'identifier les points (pixels) dans celle-ci où une variation brusque de l'intensité se produit. Dans l'approche proposée un certain nombre de fourmis se déplacent sur le graphique multidimensionnel de l'image pour trouver les pixels en question, leur mouvement est guidé par la variation locale des valeurs de l'intensité des pixels et les traces des phéromones, à la fin de ce processus, une carte contours de l'image originale est établit.

IV.6.1. Formulation de l'OCF

L'image est considérée comme une grille bidimensionnelle où l'ensemble de points (pixels) sont connectés entre eux.

Dans l'OCF utilisé pour notre problématique, les fourmis bougent d'un nœud (pixel) à un autre dans le graphique de l'image, les étapes suivies en se déplaçant sont illustrées par le tableau suivant :

| |
|---|
| <ul style="list-style-type: none"> ➤ Initialisation de la position aléatoire des K fourmis, et la matrice des phéromones initiales τ_0 ➤ Construction de la matrice de visibilité ❖ Pour le nombre d'itération $n=1 : N$, faire <ul style="list-style-type: none"> ❖ Pour le nombre d'étapes de constructions $l=1 : L$, faire <ul style="list-style-type: none"> ❖ Pour le nombre de fourmis $k= 1 : K$, faire <ul style="list-style-type: none"> ➤ Répartition aléatoire des K fourmis ➤ Choisir et aller vers le prochain pixel voisin ➤ Mettre à jour la trace de phéromone du pixel visité |
| Fin |
| Fin |
| <ul style="list-style-type: none"> ➤ Mettre à jour tous les pixels visités (τ_{finale}) |
| Fin |
| <ul style="list-style-type: none"> ➤ Eliminer les mauvaises solutions |

Table 6 : Les étapes de construction de la solution

Comme le montre bien ce cadran, le processus d'identification de ces points suit les étapes suivantes :

- ✓ Processus d'initialisation ;
- ✓ Processus de construction et de déplacement ;
- ✓ Processus de mise à jour ;
- ✓ Procédé de décision.

IV.6.1.1.Processus d'initialisation

Chaque fourmi est assignée à une position (pixel) aléatoire dans le graphique de l'image qui a une dimension $M \times M$, et à chaque position (pixel) dans l'image nous allons lui assigner une valeur entre 0 et 1 appelées valeur initiale de la phéromone (valeurs sont identiques pour tous les pixels), cela conduit à la construction d'une matrice qui a la même dimension que celle de l'image appelée *matrice de traces ou phéromones initiale* « τ_0 ».

IV.6.1.2.Construction de la matrice d'information (visibilité)

En outre, une autre matrice appelée matrice de visibilité est construite à base de la variation locale des valeurs d'intensité I entre chaque pixel (i, j) de l'image et ses voisins.

La figure suivante montre les différentes combinaisons de voisinage d'un pixel.

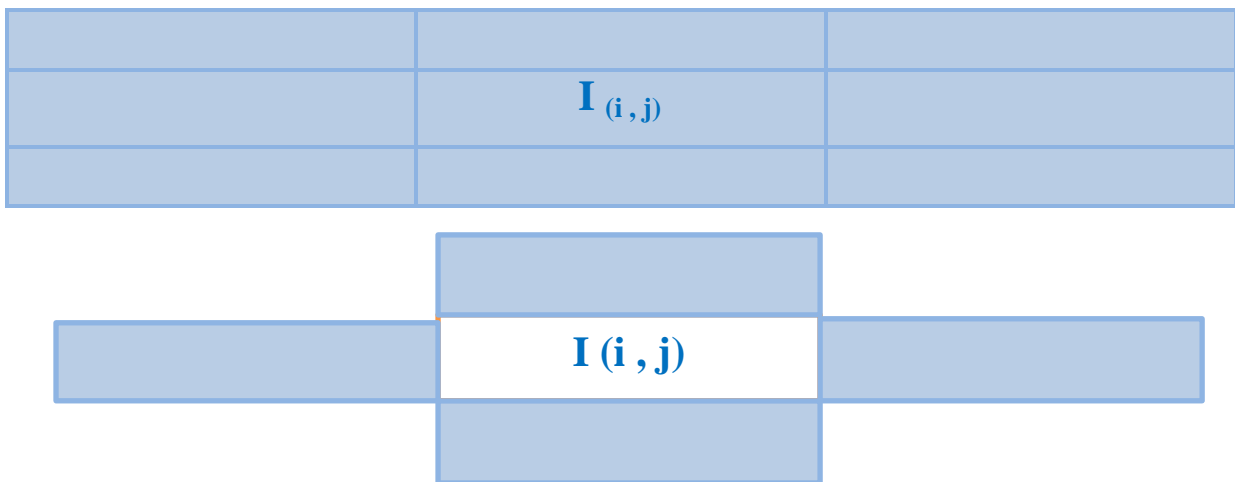


Figure 51 : Les voisins du pixel $I_{(i, j)}$ (8 et 4 connexions de voisinage)

L'information heuristique au pixel (i, j) est déterminée par :

$$n_{i, j} = \frac{Vc(I_{i, j})}{\sum_{i=1}^M \sum_{j=1}^M Vc(I_{i, j})} \quad (IV.3)$$

$I_{i, j}$: c'est l'intensité du pixel

$\sum_{i=1}^M \sum_{j=1}^M Vc(I_{i, j})$: Facteur de normalisation

$Vc(I_{i, j})$: est une fonction qui opère sur le groupe local autour du pixel en question, elle dépend de la variation des valeurs d'intensité dans le groupe local, elle est calculée comme suit ([28], [33]) :

$$V_C(I_{i,j}) = |I_{i-1,j-1} - I_{i+1,j+1}| + |I_{i-1,j} - I_{i+1,j}| + |I_{i-1,j+1} - I_{i+1,j-1}| + |I_{i,j-1} - I_{i,j+1}| \quad (IV.4)$$

| | | |
|-----------------|---------------|-----------------|
| $I_{(i-1,j-1)}$ | $I_{(i-1,j)}$ | $I_{(i-1,j+1)}$ |
| $I_{(i,j-1)}$ | $I_{(i,j)}$ | $I_{(i,j+1)}$ |
| $I_{(i+1,j-1)}$ | $I_{(i+1,j)}$ | $I_{(i+1,j+1)}$ |




Figure 52 : Configuration locale pour calculer la variation d'intensité au pixel (i, j)

IV.6.1.3. Déplacement des fourmis

Le déplacement d'une fourmi d'un pixel (i₀, j₀) à autre (i, j) qui lui est adjacent, suit une règle pseudo aléatoire.

La probabilité de transition pour explorer les autres pixels est donnée par :

$$P^{(n)}(i_0, j_0), (i, j) = \begin{cases} \frac{(\tau_{i,j}^{(n-1)})^\alpha * (n_{i,j})^\beta}{\sum_{(i,j) \in \varphi(i_0, j_0)} (\tau_{i,j}^{(n-1)})^\alpha * (n_{i,j})^\beta} & \text{si } (i, j) \in \varphi(i_0, j_0) \\ 0 & \text{sinon} \end{cases} \quad (IV.5)$$

(n) : Indice de l'itération;

$\tau_{i,j}^{(n-1)}$: La valeur du phéromone du pixel (i,j) ;

$\varphi(i_0, j_0)$: L'ensemble des pixels voisins du point (i,j) ;

$n_{i,j}$: Information heuristique du pixel (i, j) appelée aussi la visibilité ;

α : Une constante entre 0 et 1 contrôle l'influence de la phéromone ;

β : Une constante entre 0 et 1 contrôle l'influence de l'information heuristique.

Une fourmi peut donc se déplacer à n'importe quel pixel adjacent, mais, son mouvement est limité par la condition qu'une fourmi ne se déplace qu'à un nœud qu'elle n'a pas récemment visité (au cours de la même itération).

Cette condition empêche les fourmis de visiter le même ensemble de nœuds à plusieurs reprises, ce qui conduit à la réduction de l'espace de recherche. Afin d'éviter cela et pour retenir les nœuds récemment visités, chaque fourmi a une mémoire.

IV.6.1.4. Mise à jour

Au cours de son déplacement d'un pixel à un autre, la fourmi marque son passage en mettant immédiatement à jour la valeur de phéromone existante en ce point, ce que nous appelons la mise à jour locale, elle est donnée par :

$$\tau_{i,j}(n+1) = (1-\rho) * \tau_{i,j}(n) + \rho \Delta \tau_{(i,j)} \quad (\text{IV.6})$$

ρ : est une constante entre 0 et 1, elle porte le nom de coefficient d'affaiblissement de phéromone ;

$$\Delta \tau_{(i,j)} = \frac{1}{n_{i,j}}$$

A la fin de procédé de construction « **L** » de toutes les fourmis mises en œuvre ou à la fin de chaque itération, une autre mise à jour vient d'être appliquée à la matrice de phéromone des pixels visités par au moins une seule fourmi, c'est ce que nous appelons la mise à jour globale, cette dernière est décrite par la formule suivante :

$$\tau_{i,j}(n+1) = (1-\rho) * \tau_{i,j}(n) + \rho \tau_0(i,j) \quad (\text{IV.7})$$

IV.6.1.5. Procédé de décision

Il s'agit de la dernière étape de notre processus de construction de la solution, donc de détection de contours. La matrice finale de phéromones construite par les fourmis est employée pour prendre une décision sur chaque pixel de l'image, cette décision nous permet de dire si un pixel est contour ou pas et d'éliminer les pixels non contours.

La décision est prise après l'application d'un seuil sur la matrice finale de phéromone « $\tau^{(\text{finale})}$ ». Cette décision est binaire, elle est prise pour chaque pixel, par l'application d'un seuil « **T** » sur la matrice finale de phéromones « $\tau^{(\text{finale})}$ ».

Pour cela un $T^{(0)}$ est choisi comme la valeur moyenne de la matrice de phéromone finale, ainsi, les valeurs de cette dernière sont classifiées dans deux catégories selon le critère qu'une valeur est inférieure $T^{(0)}$ ou supérieure à $T^{(0)}$. Alors le nouveau seuil est calculé comme la moyenne de deux valeurs moyennes de chacune de deux catégories. Ce processus est répété jusqu'à ce que la valeur- seuil ne change pas (en termes de tolérance définie par l'utilisateur) [33].

Le déroulement de ce procédé est détaillé comme suit :

Etape 1 : initialisation de $T^{(0)}$

$$T^{(0)} = \frac{\sum_{i=1}^M \sum_{j=1}^M \tau_{ij}^{(finale)}}{M * M} \quad (IV.8)$$

Etape 2 : Séparer la matrice de phéromone $\tau^{(finale)}$ en deux classes, où la première est inférieure à $T^{(1)}$ et la deuxième classe est supérieure à cette valeur.

Après, nous calculons la moyenne de chacune des deux classes par :

$$m_L^{(l)} = \frac{\sum_{i=1}^M \sum_{j=1}^M g_{T^{(l)}}^L \tau_{ij}^{(finale)}}{\sum_{i=1}^M \sum_{j=1}^M h_{T^{(l)}}^L \tau_{ij}^{(finale)}} \quad (IV.9)$$

$$m_U^{(l)} = \frac{\sum_{i=1}^M \sum_{j=1}^M g_{T^{(l)}}^U \tau_{ij}^{(finale)}}{\sum_{i=1}^M \sum_{j=1}^M h_{T^{(l)}}^U \tau_{ij}^{(finale)}} \quad (IV.10)$$

Avec :

$$g_{T^{(l)}}^L(x) = \begin{cases} x & \text{si } x \leq T^{(l)} \\ 0 & \text{sinon} \end{cases} \quad (IV.11)$$

$$h_{T^{(l)}}^L(x) = \begin{cases} 1 & \text{si } x \leq T^{(l)} \\ 0 & \text{sinon} \end{cases} \quad (IV.12)$$

$$g_{T^{(l)}}^U(x) = \begin{cases} x & \text{si } x \geq T^{(l)} \\ 0 & \text{sinon} \end{cases} \quad (\text{IV.13})$$

$$h_{T^{(l)}}^U(x) = \begin{cases} 1 & \text{si } x \geq T^{(l)} \\ 0 & \text{sinon} \end{cases} \quad (\text{IV.14})$$

Etape 3 : mettre à jour la valeur de $T^{(l)}$

$$T^{(l)} = \frac{m_L^{(l)} - m_U^{(l)}}{2} \quad (\text{IV.15})$$

Etape 4 : comparer les valeurs de $T^{(l)}$ entre chaque deux itérations successives :

$$|T^{(l)} - T^{(l-1)}| > \varepsilon \quad (\text{IV.16})$$

Avec :

ε : est une constante choisie par l'opérateur ;

Si cette condition est satisfaite alors nous revenons à l'étape 2, sinon nous arrêtons, et la décision sur tous les pixels est prise si c'est un contour ou pas.

$$E_{i,j} = \begin{cases} 1 \text{ si } \tau_{i,j}^{(N)} \geq T^{(l)} \\ 0 \text{ sinon} \end{cases} \quad (\text{IV.17})$$

IV.6.2. Algorithme de l'approche proposée

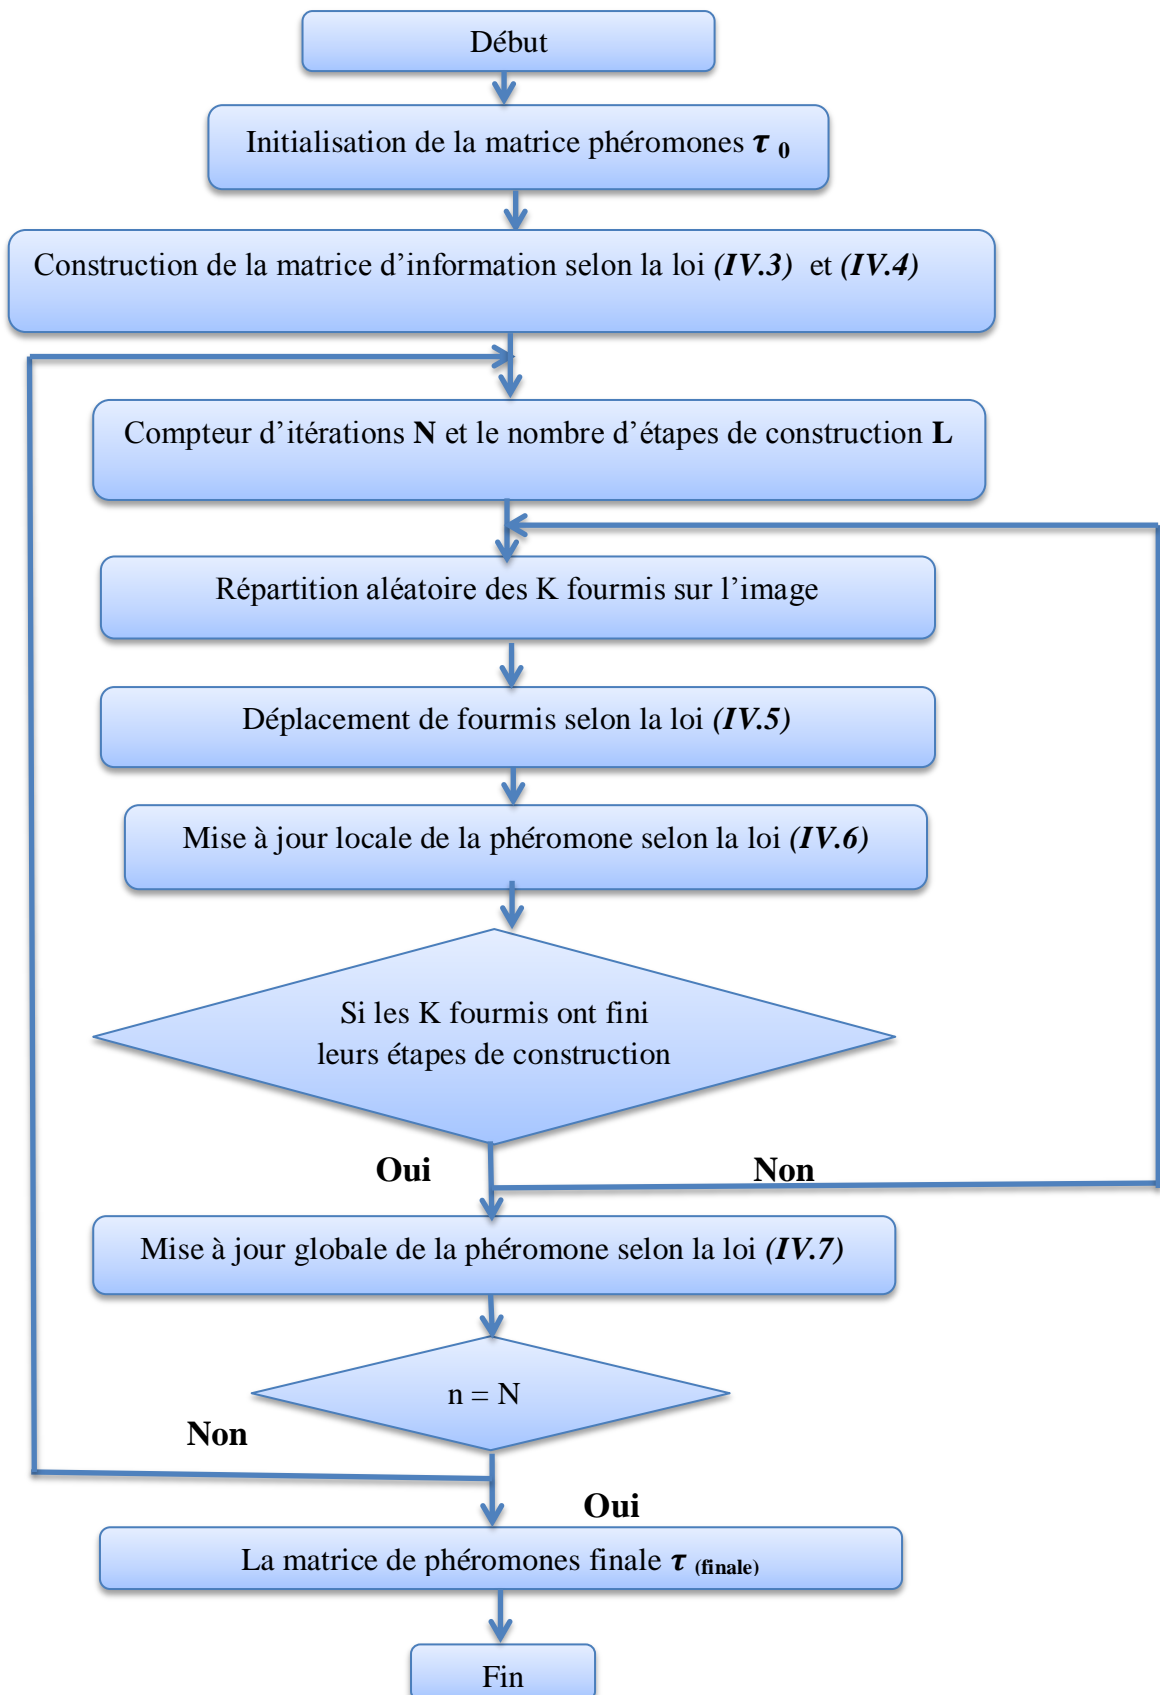


Figure 53 : Les étapes d'implémentation de l'OCF pour segmenter une image en contours

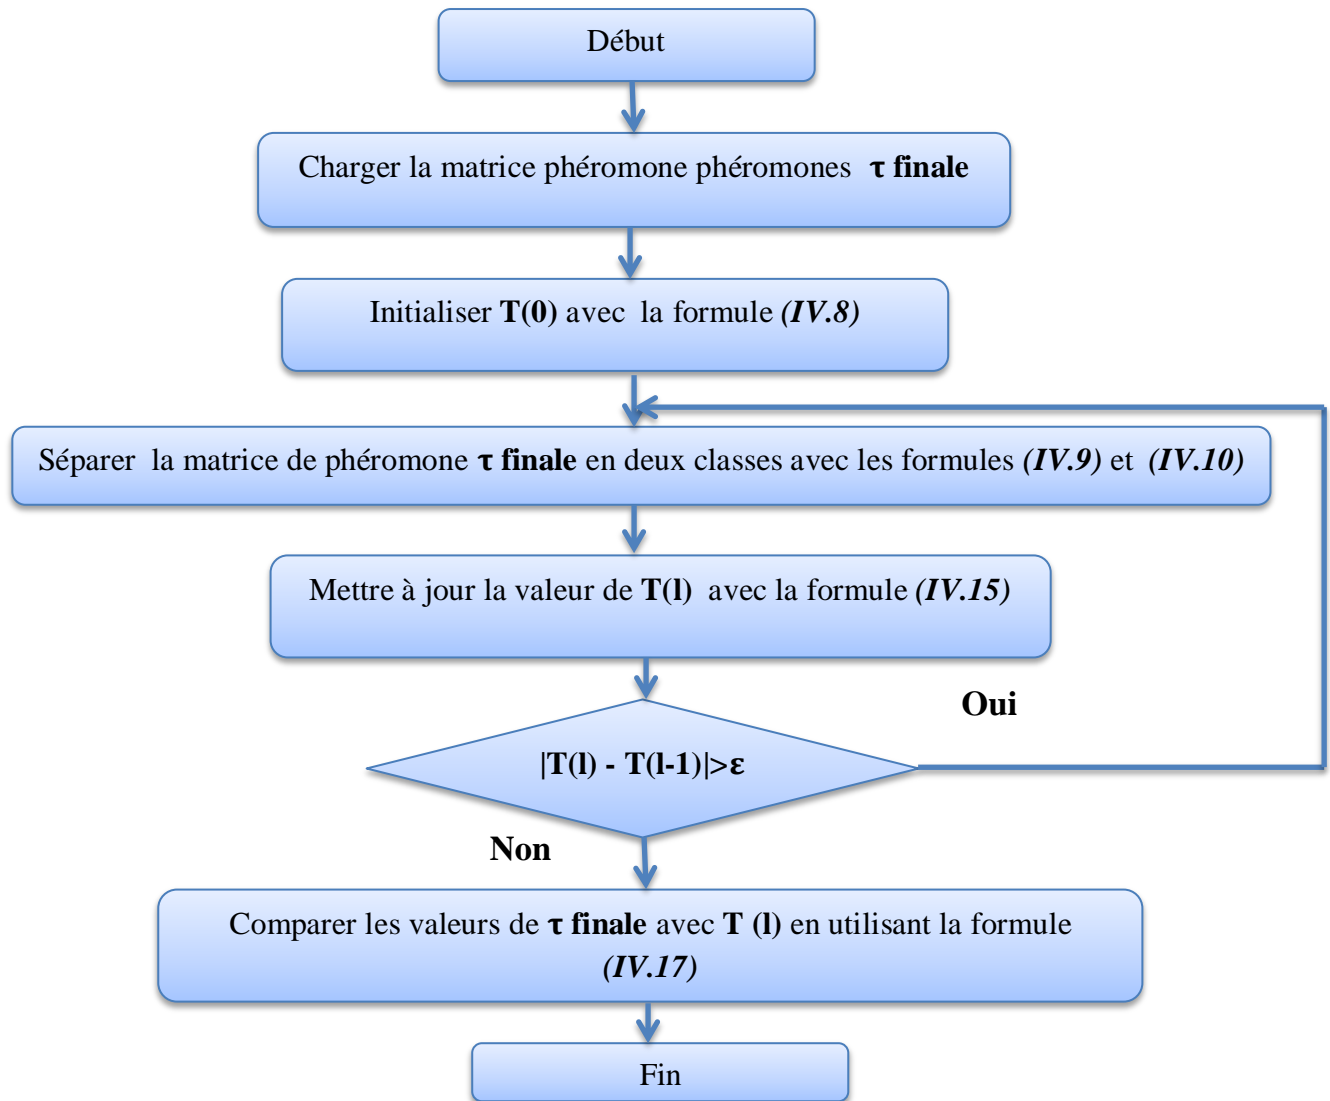


Figure 54 : Prise de décision sur le résultat trouvé par l'OCF

(Si le pixel est contour ou pas)

IV.7. Discussion

Les comportements simples inspirés de la nature, qu'effectuent les fourmis dans l'optimisation du chemin et la classification des couvains ont donné naissance à des réflexions chez les chercheurs pour l'utilisation de la colonie de fourmis artificielle pour la détection des contours des images. Ceci en assignant chaque fourmi à une position (pixel) aléatoire, ensuite les fourmis se déplacent à n'importe quel pixel adjacent qu'elle n'a pas récemment visité puis met à jour chaque pixel visité et prend la décision si ce pixel est contour ou pas en respectant le critère du seuil.

Cette démarche sera appliquée dans le chapitre suivant pour la détection des contours des images.

Chapitre V

Applications et Résultats

V.1. Préambule

Pour aboutir à des solutions de plus en plus efficaces, des algorithmes peuvent s'enchaîner les uns à la suite des autres. L'idée principale est d'hybrider deux algorithmes différents pour avoir des résultats plus pertinents. L'aspect le plus important est qu'il n'y a pas de limites imposées par le logiciel sur le nombre ou les combinaisons particulières d'algorithmes qu'il est possible d'effectuer.

Dans notre application, nous appliquerons un algorithme pour classifier les pixels d'une image en régions dans le but de la segmenter tel que les K-Plus Proches Voisins avant d'affiner les résultats par l'algorithme d'Optimisation par Colonies de Fourmis en détectant les contours de ses régions.

La méthode de segmentation d'images par classification des K-Plus Proches Voisins définit une partition de l'image en un ensemble de classes. Chaque classe rassemble des pixels ayant des vecteurs de caractéristiques (souvent réduit au niveau de gris) aussi similaires que possible et les classes obtenues doivent être aussi distinctes que possible. Elle identifie les classes de pixels présentes dans l'image et affecte à chaque pixel une étiquette indiquant la classe à laquelle il appartient.

L'application de l'OCF sera faite dans le but de la détection des contours des images utilisée. Nous exposerons les résultats des tests que nous avons effectués sur des images médicales IRM, satellitaires et METEOSAT.

Les algorithmes de segmentation ont été implémentés en langage de programmation MATLAB.

V.2. Méthodologie

Le choix des images à utiliser a été fait dans le but de pouvoir exprimer la possibilité de l'application de notre méthode sur différents types d'images (IRM, satellitaires et METEOSAT).

Afin d'analyser et de commenter les différents résultats obtenus par l'application de notre méthode sur les différents types d'images et pour notamment mettre en évidence ses limites et de proposer comme perspectives les améliorations possibles, nous avons appliqué en premier lieu l'algorithme d'Optimisation de la Segmentation par Colonies de Fourmis Artificielles pour essayer de détecter les contours des images.

Ensuite, nous avons opté pour le regroupement des pixels en classes (régions) différentes par l'application de l'algorithme des KPPV, pour pouvoir finalement détecter les contours de ces zones par l'application de l'OCF: il s'agit de la méthode hybride proposée.

V.3. Application de la méthode

Notre méthode a été testée sur des images médicales à résonance magnétique, des images satellitaires et des images METEOSAT téléchargées toutes sur Internet. Le principe de la technique est élaborée en trois applications principales : la première se base sur l'application de l'OCF pour la détection des contours, ensuite la classification des pixels par l'algorithme des K-PPV et finalement l'application de l'OCF pour une meilleure détection des contours de ces régions, il s'agit donc de la méthode hybride.

V.3.1. Détection des contours par l'OCF

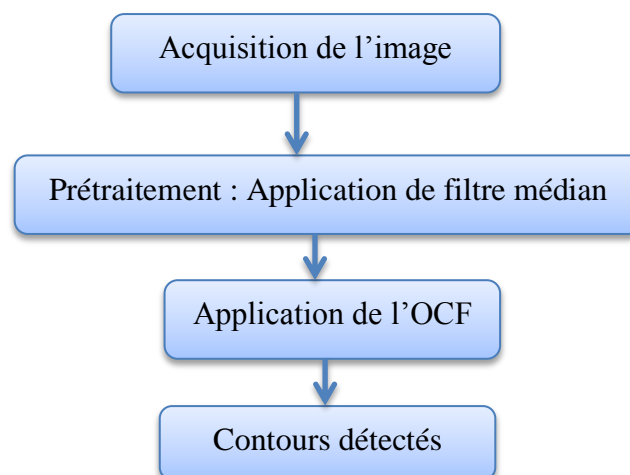


Figure 55 : Etapes de détection des contours par l'OCF

V.3.2. Classification des pixels par l'algorithme des KPPV

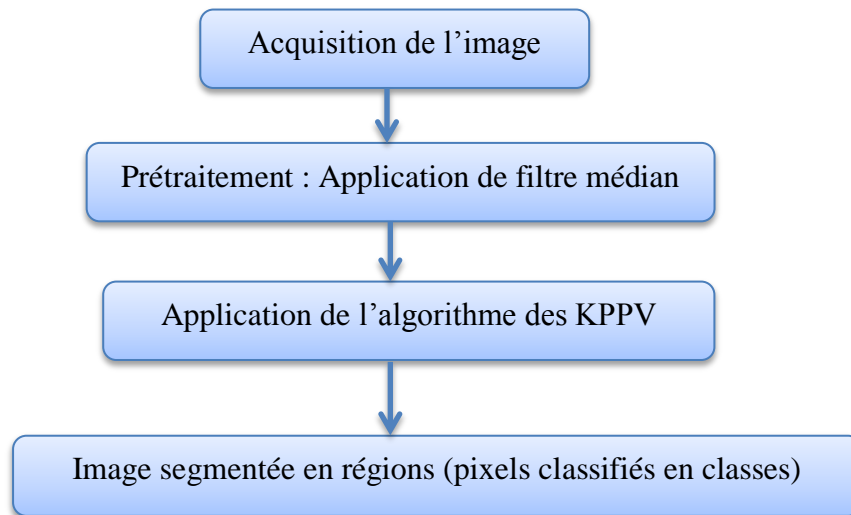


Figure 56 : Etapes de segmentation d'images par KPPV

V.3.3. Application de la méthode hybride proposée

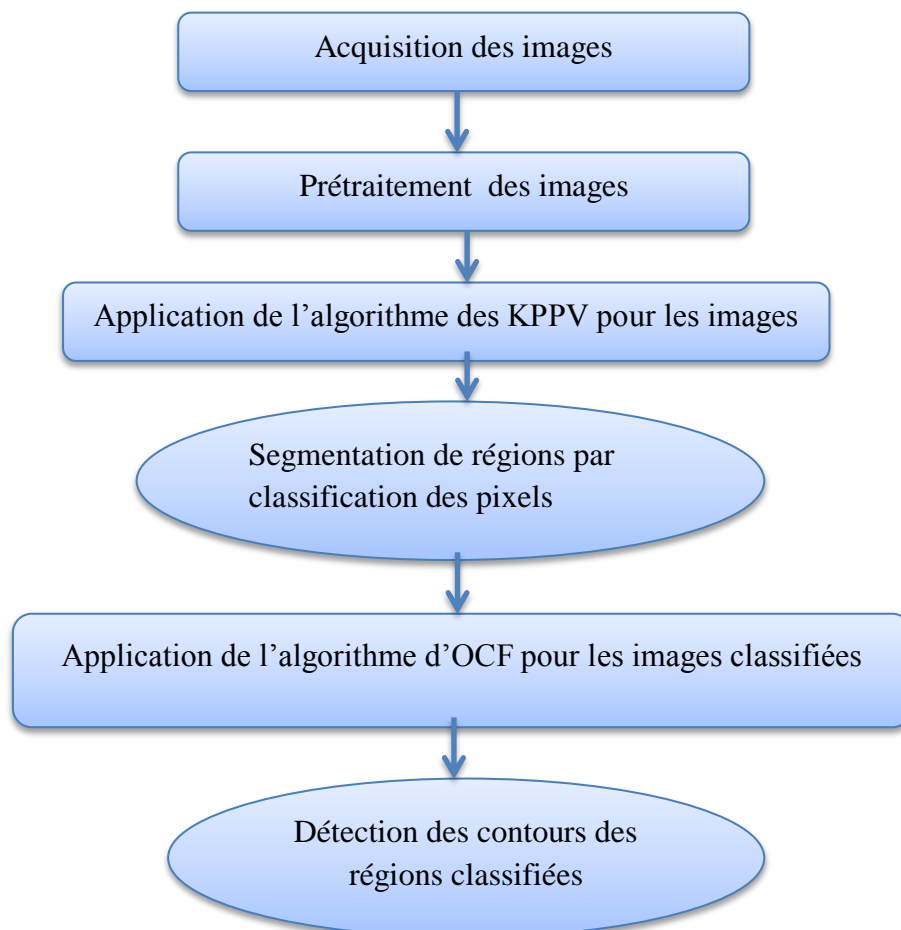


Figure 57 : Les étapes de la méthode hybride proposée

V.4. Tests et Résultats

Les résultats obtenus dans l'application de notre méthode sont donnés ci-dessous en respectant la démarche illustrée précédemment. Nous avons commencé par l'application de l'OCF pour la détection des contours, l'application des KPPV dans un deuxième temps et nous enchaînons par l'hybridation des deux techniques.

V.4.1. Application aux images IRM

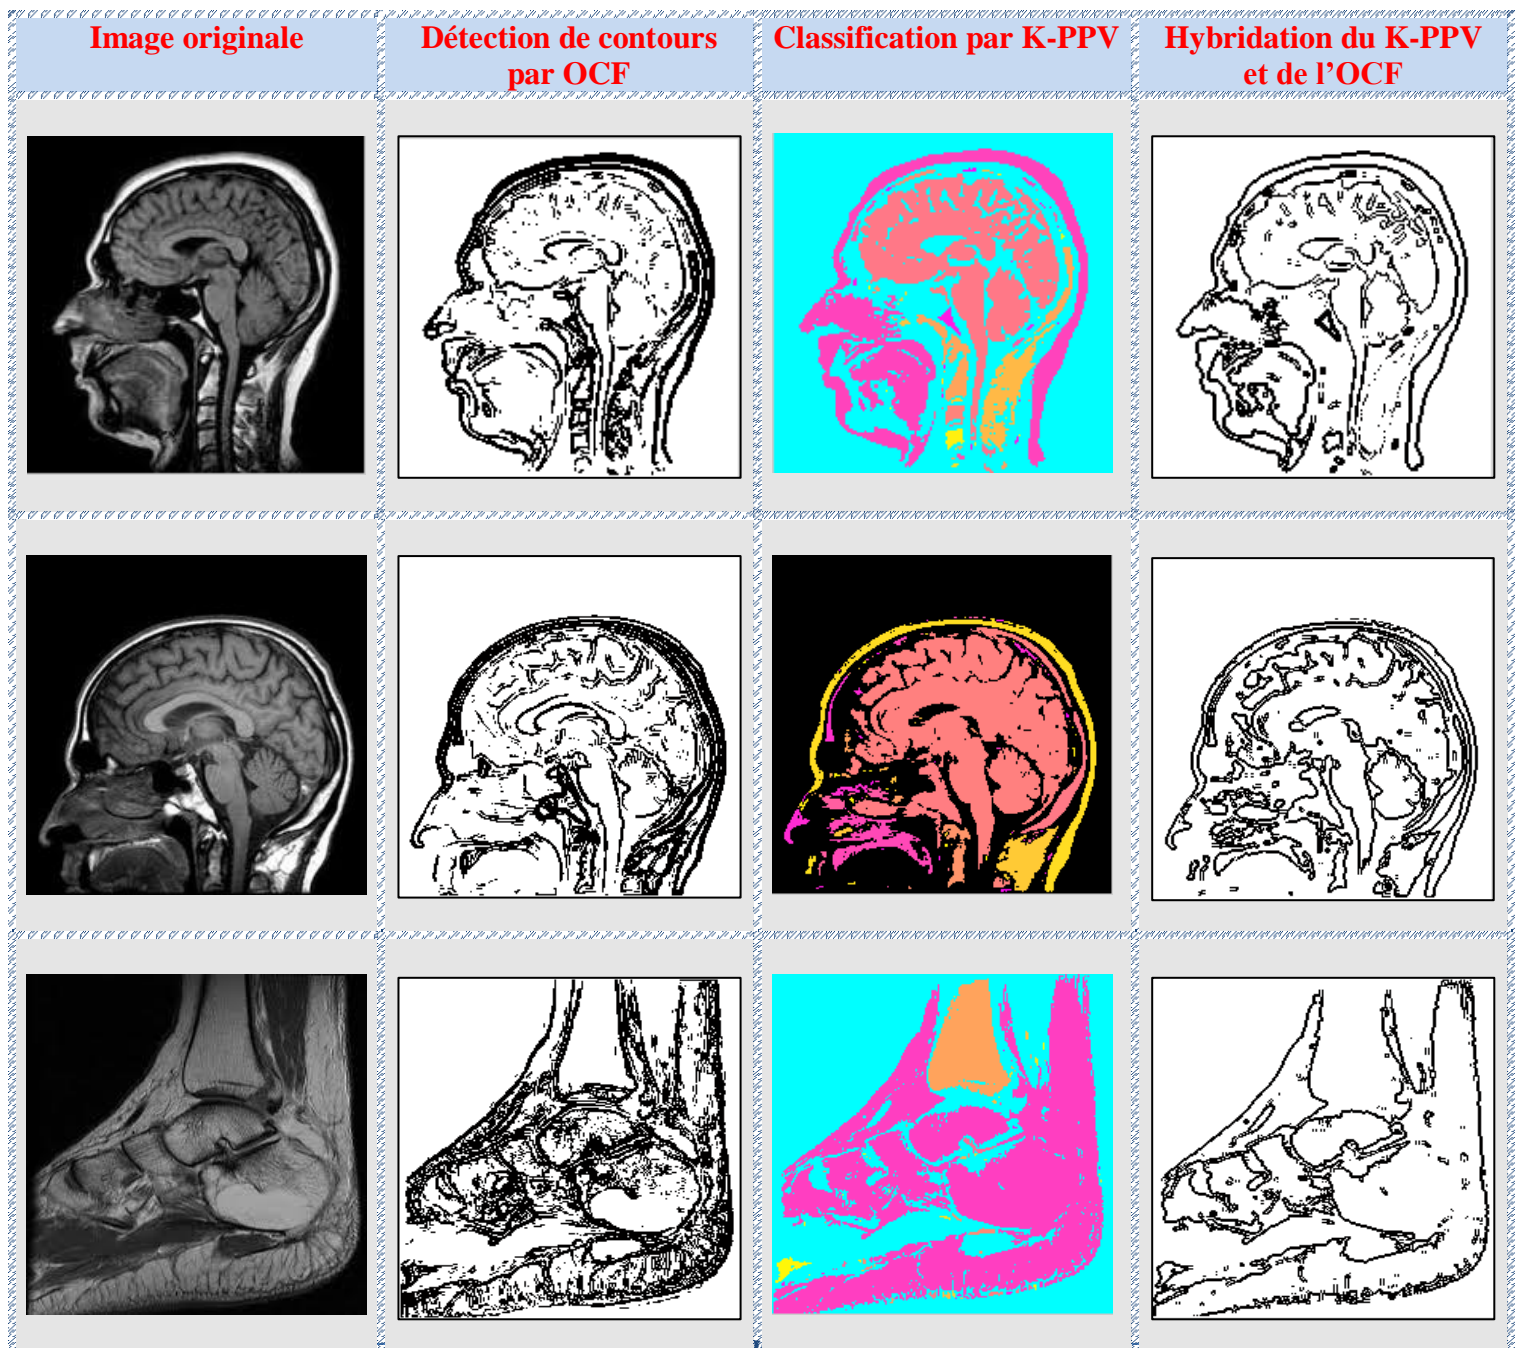



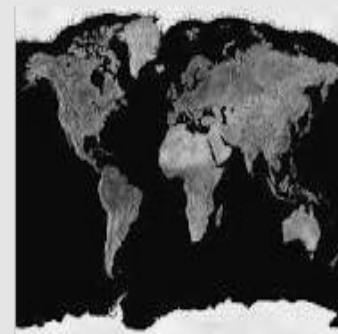


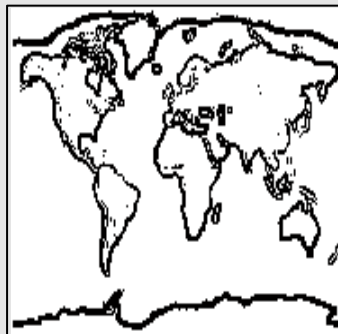
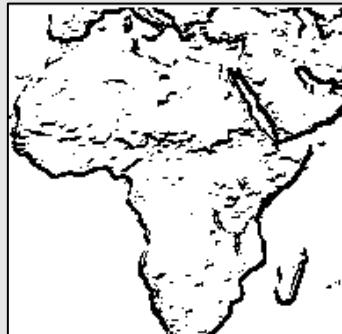
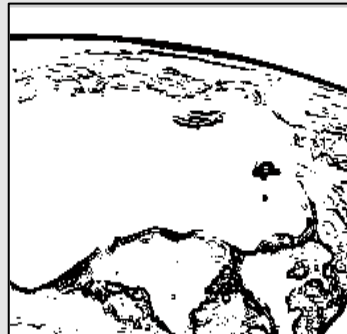








Figure 58 : Résultats obtenus dans l'application de notre méthode sur des images IRM

V.4.2. Application aux images satellitaires

| | | | |
|---|---|--|---|
| <p>Image originale</p> |  |  |  |
| <p>Image En Niveau De Gris</p> |  |  |  |
| <p>Détection de Contours Par OCF</p> |  |  |  |
| <p>Classification par KPPV</p> |  |  |  |




**Hybridation
du K-PPV et
de l'OCF**





**Image
originale**



**Image
En
Niveau
De
Gris**



**Détection de
Contours
Par
OCF**



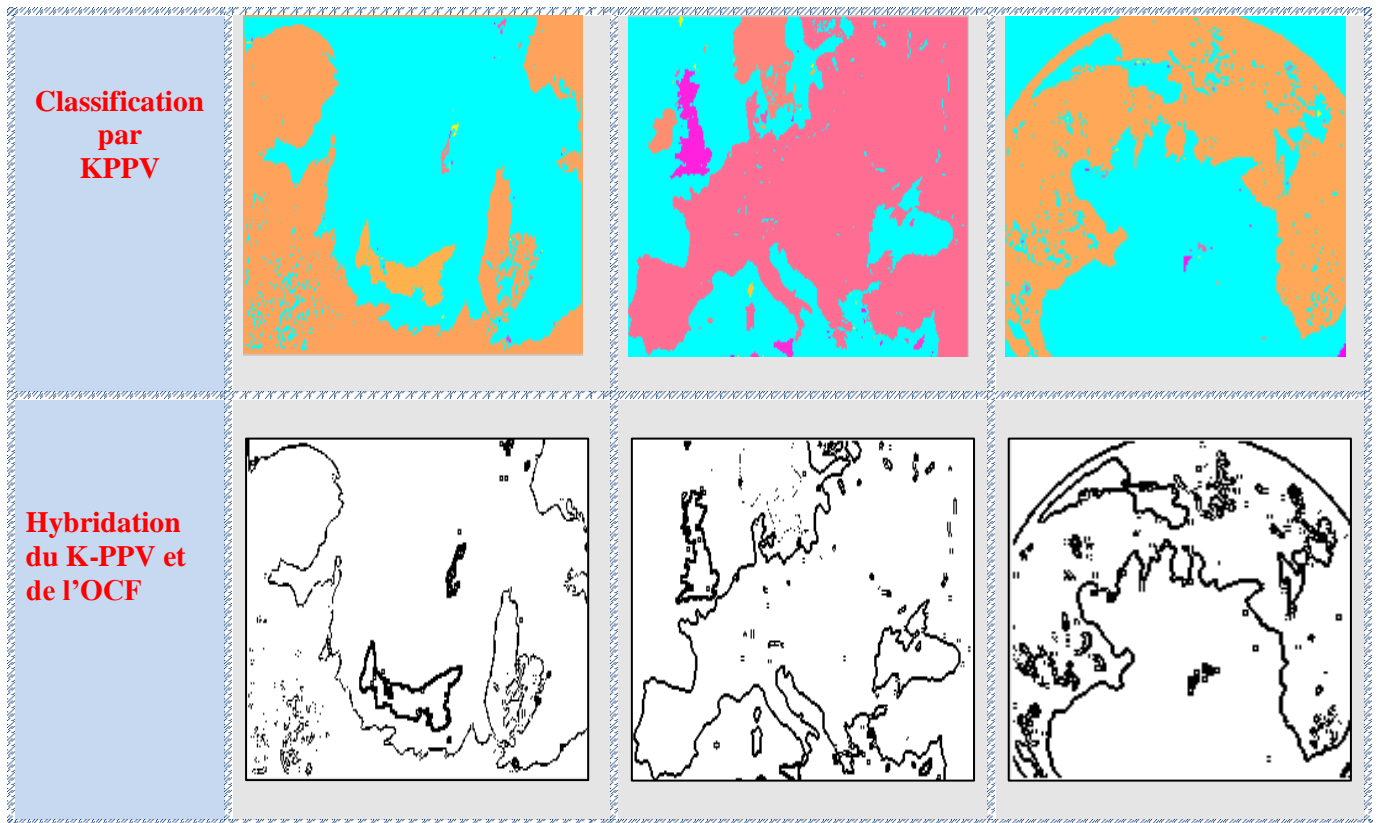
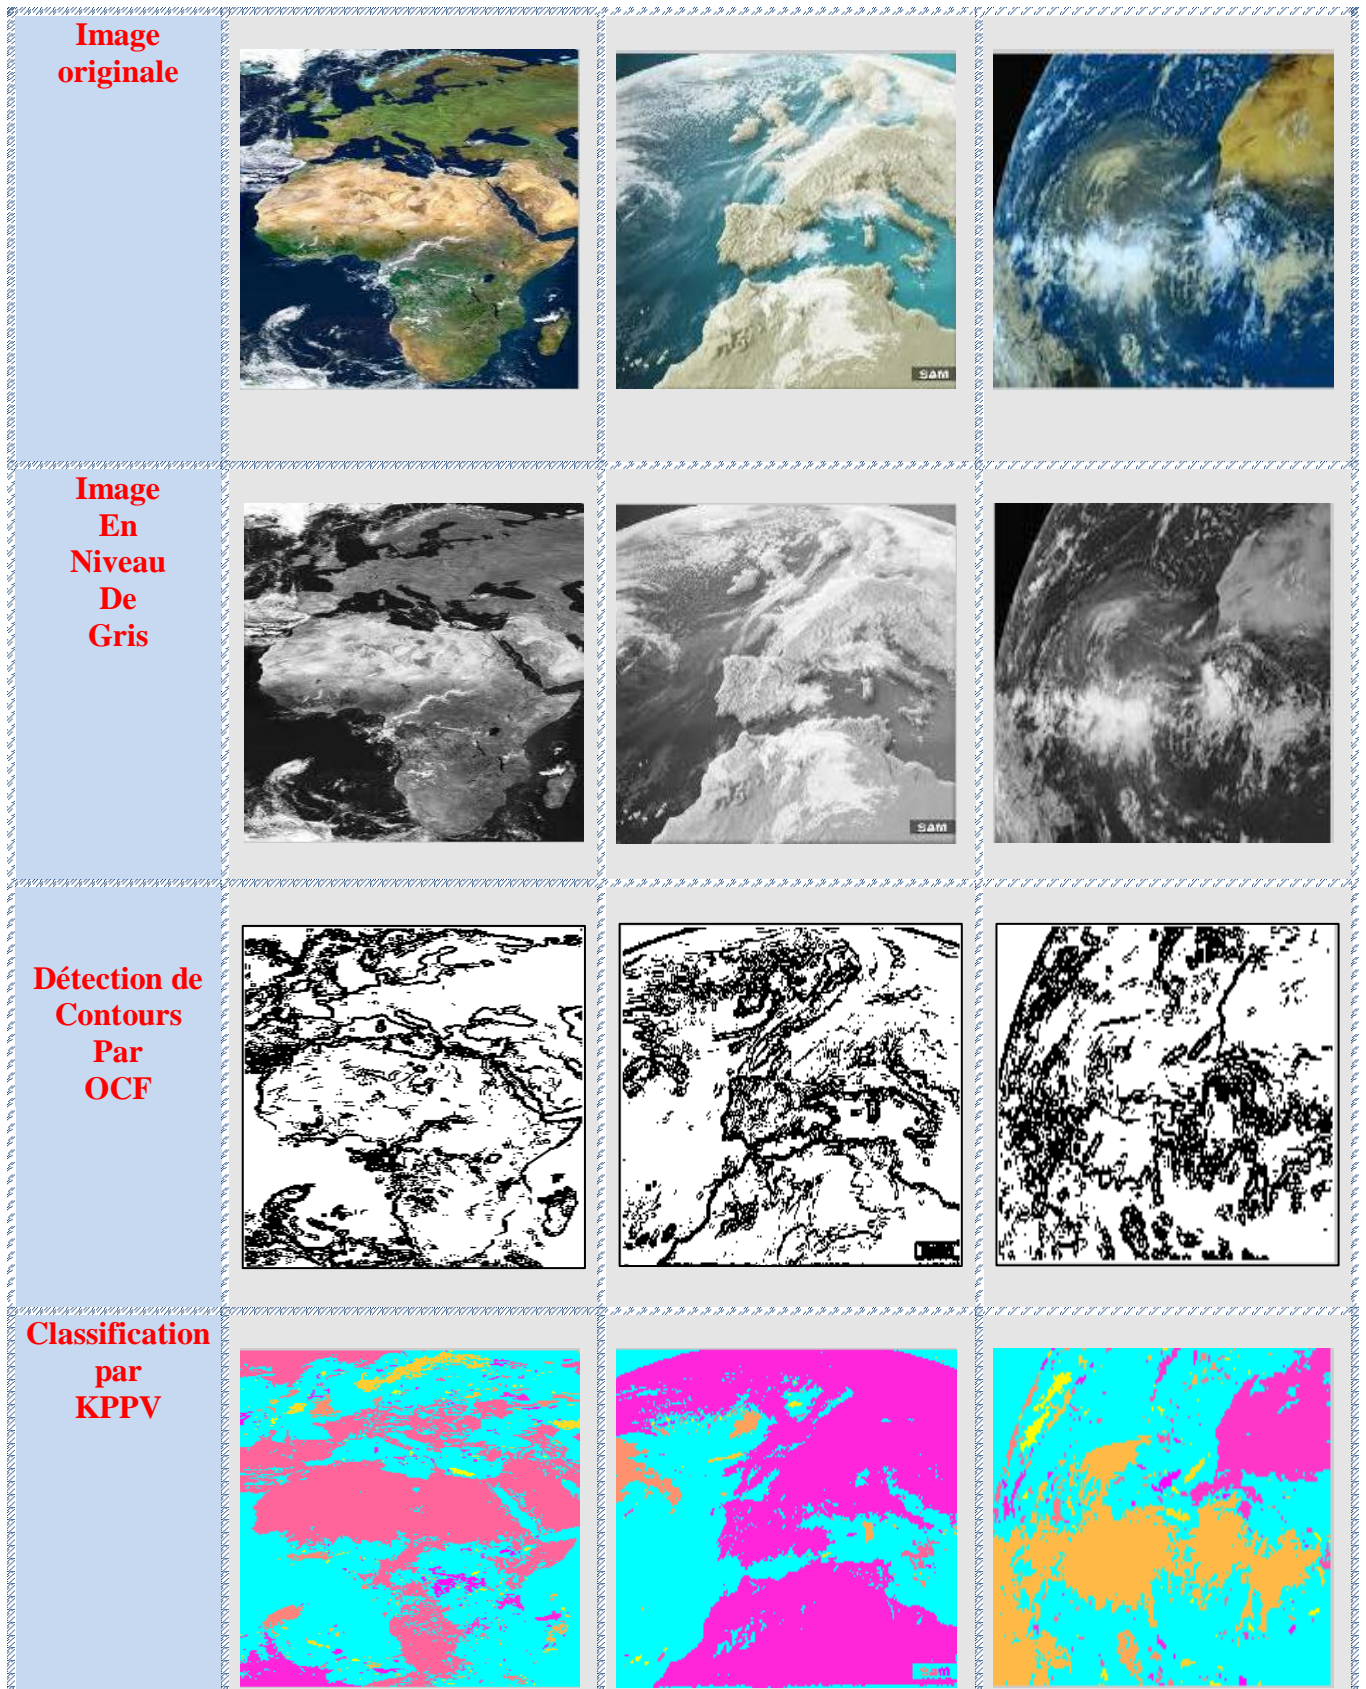





Figure 59 : Résultats obtenus dans l'application de notre méthode sur des images satellitaires



V.4.3. Application aux images METEOSAT





**Hybridation
du K-PPV et
de l'OCF**





**Image
originale**



**Image
En
Niveau
De
Gris**



**Détection de
Contours
Par
OCF**



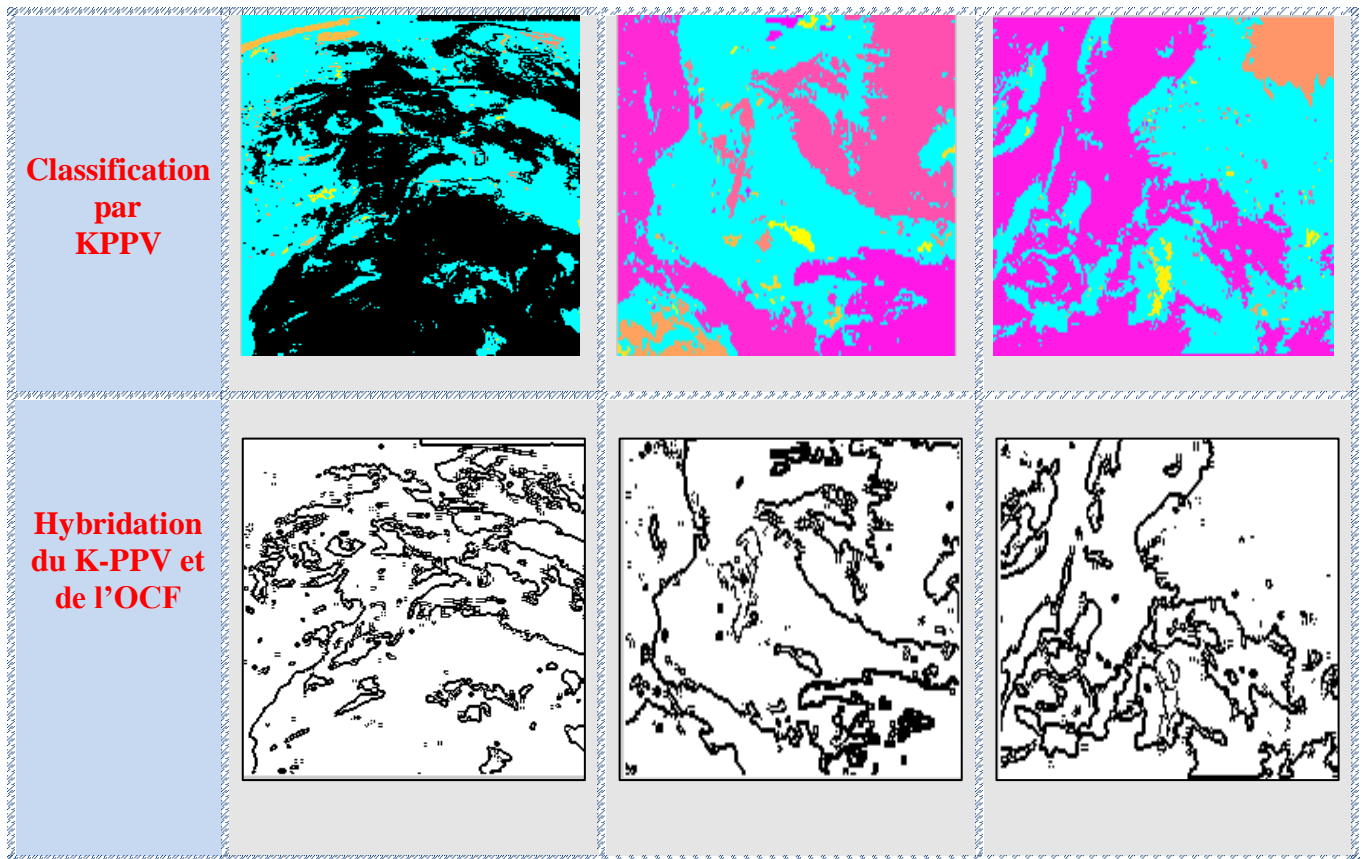


Figure 60 : Résultats obtenus dans l'application de notre méthode sur des images METEOSAT

V.5. Interprétation des Résultats

Comme nous l'avons vu dans les sections précédentes, l'OCF est une méthode itérative. Nous avons pu constater visiblement que la qualité des résultats de la segmentation s'améliore en augmentant le nombre d'itération qui ne dépasse pas dans notre cas le nombre de dix. Nous avons remarqué que la qualité restituée reste visiblement inchangée.

Visiblement, les différents résultats obtenus, pour les différents types d'images utilisées, par la méthode des Fourmis Artificielles sont très satisfaisants, vue la qualité des contours observés malgré la complexité des images étudiées, car ces dernières contiennent des écarts très petits entre les niveaux de gris, qui sont très difficiles à détecter.

L'optimisation de la segmentation par l'approche biomimétique des Colonies de Fourmis Artificielles offre une qualité qui dépend de l'optimisation des différents paramètres de celle-ci, car nous avons remarqué qu'ils influent considérablement sur le résultat final.

Les paramètres de l'OCF retenus dans notre application sont donnés par le tableau suivant :

| Paramètre | Sa valeur retenue |
|---|-----------------------------------|
| Alpha (α) | 1 |
| Beta (β) | 0.01 |
| Rho (ρ) | 0.001 |
| Nombre d'itérations (N) | 07 |
| Nombre de fourmis (K) | $\sqrt{\text{taille de l'image}}$ |
| Nombre de mouvement de déplacement (L) | 40 |
| Epsilon (ϵ) | 0.1 |

Table 7 : Les valeurs des paramètres de l'OCF retenues dans notre étude

Dans le but de l'amélioration de ces résultats, nous avons tenté d'hybrider cette méthode avec une autre technique de type région (classification des pixels par les K-Plus Proches Voisins), nous avons donc pu remarquer après l'analyse visuelle qu'une bonne segmentation de régions a été faite par l'algorithme des K-PPV. Les pixels apparaissent bien classés, de ce fait, les régions sont convenablement séparées et contiennent chacune l'essentiel de l'information.

De plus, nous avons remarqué que la segmentation par les K-PPV dépend du choix de la distance à utiliser, le nombre de voisins à prendre en compte ainsi que le nombre de classe contenu dans la base d'apprentissage.

La distance que nous avons utilisée est la distance euclidienne, le nombre de classe dépend du nombre d'objets que contient chaque image, détectés par l'algorithme des K-PPV.

Concernant le nombre de voisins K à considérer, comme la littérature le montre, son choix est bien un compromis entre la bonne résolution et la sensibilité des pixels au bruit : une faible valeur de K va donner une bonne résolution c'est-à-dire définir des frontières compliquées entre classes mais les pixels classés sont très sensible au bruit, par contre une grande valeur de K aura un comportement inverse, lissant les frontière mais restent peu sensible au bruit. Les tests que nous avons effectués ont montré qu'en prenant K=6, on obtenait une bonne classification des pixels.

L'hybridation, quant à elle, montre des frontières des régions classifiées, parfaitement localisées, des contours clairs et fermés. Nous pouvons donc conclure des meilleurs résultats obtenus par cette méthode par rapport à la méthode d'OCF appliquée seule et donnant ainsi, une bonne carte contours des images originales utilisées dans notre travail.

Ainsi, nous pouvons dire que la méthode hybride proposée est très intéressante sur la qualité restituée et le nombre de contours détectés par rapport à la méthode d'Optimisation par Colonies de Fourmis utilisée individuellement.

De ce fait, nous constatons que la coopération entre les régions et les contours a joué un grand rôle dans l'amélioration des résultats de la segmentation.

V.6. Discussion

Dans ce travail, nous avons développé une nouvelle méthode de segmentation d'images basée sur l'optimisation de la segmentation par l'approche biomimétique des colonies de fourmis artificielles.

Notre méthode a été utilisée sur des images IRM, satellitaires et METEOSAT. Malgré leur complexité, les contours ont été bien détectés, notamment les régions ont été parfaitement classifiées par les K-PPV et la coopération entre les régions et les contours a donné une amélioration dans les résultats obtenus.

Les résultats expérimentaux ont montré l'efficacité de notre méthode sur les différents types d'images utilisées dans notre travail et ont prouvé sa robustesse en faisant une analyse visuelle des différents résultats obtenus.

Conclusion

Dans ce mémoire, nous nous sommes intéressés aux possibilités d'optimiser la segmentation d'images par les méthodes biomimétiques notamment la méthode des Fourmis Artificielles en détectant ses contours. Rappelons qu'un contour peut être défini comme une frontière entre deux régions différentes.

Dans la partie théorique, nous avons développé les différentes méthodes de prétraitement permettant l'amélioration de la qualité de l'image à segmenter et nous avons présenté un état de l'art des différentes techniques de segmentation et les approches biomimétiques qui ont été trouvées dans la littérature pour la détection des contours d'images.

Le but recherché dans ce mémoire est de segmenter des images en contours par une approche hybride et de prouver que la coopération régions-contours donne de meilleurs résultats par rapport à la méthode proposée appliquée seule et non hybride.

Pour cela, dans la partie pratique, nous avons implémenté la méthode des fourmis artificielles non hybride et nous l'avons testée sur des images différentes (IRM, satellitaires, METEOSAT) prétraitées pour tenter d'extraire les différents contours. Dans un deuxième temps, nous avons essayé de classifier les pixels des différentes images et détecter les régions, puis, finalement, nous avons implémenté et testé la méthode de l'OCF sur ces images classifiées pour détecter les contours de leurs différentes régions: il s'agit donc de l'application de la méthode hybride proposée des colonies de fourmis artificielles avec les K-Plus Proches Voisins.

L'évaluation visuelle des différents résultats a montré que la méthode hybride (KPPV+OCF) est plus intéressante et robuste sur les différents types d'images. Elle est plus performante que la méthode biomimétique appliquée seule vu la qualité des contours détectés par l'hybridation. Mais comme toutes les méthodes d'optimisation, les deux méthodes proposées, hybride et non hybride ont enregistré quelques inconvénients au cours d'exécution comme :

- Le nombre de paramètres, qui est relativement important. Les résultats dépendent directement de l'optimisation de ces paramètres ;
- Les contours détectés dépendent de la nature de l'image. Si deux régions de celle-ci sont très proches, la détection de contours reste incertaine pour l'OCF non hybride ;

- La fermeture et la détection des contours dépendent du prétraitement opéré sur l'image brute.

Perspectives

Comme perspectives nous proposons :

- De travailler sur des méthodes de même nature, c'est-à-dire travailler sur une méthode hybride purement biomimétique qui consiste à appliquer une méta-heuristique robuste capable de détecter toutes les régions d'une image et appliquer ensuite l'OCF pour détecter les contours des différentes régions de ces images.
- D'exploiter en même temps dans une méthode hybride, les deux phénomènes naturels observés chez les fourmis (fourragement et classification).
- D'utiliser les autres formes de coopération (coopération des résultats ou coopération mutuelle).

Le programme élaboré a été réalisé sous MATLAB, sous l'environnement Windows. On peut rappeler que MATLAB est l'abréviation de « MATrix LABoratory ». C'est un logiciel de calcul scientifique dédié plus particulièrement aux applications numériques. A l'origine, il a été conçu pour manipuler des données matricielles, ce qui a fait de ce logiciel un outil majeur de l'analyse de données, du traitement du signal, du traitement d'images, de simulation numérique, etc. Il dispose d'une syntaxe spécifique mais elle est simple et intuitive.

MATLAB propose deux types de fonctionnement :

- Un fonctionnement en ligne de commande où MATLAB exécute les instructions au fur et à mesure qu'elles sont données par l'utilisateur (MATLAB commande).
- Un fonctionnement via des scripts, dans ce cas, MATLAB exécute ligne par ligne un fichier texte que l'on désigne par programme (MATLAB Editor).

MATLAB propose également une aide très complète illustrée d'exemples, étant donnée le très grand nombre d'instructions utilisables, il est important de bien savoir l'utiliser.

Les images utilisées pour les différents tests de notre méthode peuvent être classées en trois catégories : Les images médicales IRM, METEOSAT de première et de seconde génération (MSG) et les images satellitaires.

B.1. Images médicales

L'imagerie médicale est certainement l'un des domaines de la médecine qui a le plus progressé ces vingt dernières années, puisqu'elle a vu l'irruption de la machine. Ces récentes découvertes permettent non seulement un meilleur diagnostic mais offrent aussi de nouveaux espoirs de traitement pour de nombreuses maladies en offrant des images de l'intérieur du corps humain et de comprendre le fonctionnement de ces organes.

De nombreuses techniques d'imagerie médicale ont été développées, elles sont généralement classées selon la manière d'interaction physique entre le sujet et l'appareil d'acquisition. Il existe trois grands types d'imageries fréquemment utilisées, chacun utilise des propriétés physiques différentes :

B.1.1. La tomographie à rayon X

L'imagerie tomographique, comme l'image standard à rayon X, est obtenue par la mesure de l'atténuation des rayons X à travers différents tissus. Cette atténuation dépend de l'épaisseur et de la composition des tissus traversés. De façon simple, les différents corps traversés sont l'air, la graisse, l'eau et l'os. Ces corps n'ayant pas la même composition atomique, ils répondent différemment aux faisceaux de rayons X : l'air atténue moins que l'os et l'eau plus que la graisse. Associée à des produits de contraste, cette image Scanographique donne une première idée de la localisation de la lésion.



Figure 61 : Images à rayons X

B.1.2. L'imagerie par résonance magnétique

Cette imagerie exploite les propriétés magnétiques des tissus, elle permet distinction entre tissus et tissus pathologiques. Elle offre une précision spatiale supérieure à celle des images Scanographiques car elle fournit un point de vue de la tumeur utile pour le diagnostic.



Figure 62 : Appareil IRM

Le principe de l'IRM met à profit la distribution aléatoire des protons qui possèdent des propriétés magnétiques. Le processus se fait en trois étapes. Dans un premier temps, l'IRM place le corps dans un champ magnétique très puissant (30000 fois plus puissant que celui de la terre) qui oriente tous les protons dans la même direction. Ensuite, les protons sont excités par des ondes radio qui modifient leur orientation. Enfin, la simulation est brutalement interrompue, et l'appareil recueille une onde dite de « résonance » par des antennes spécialement conçues. L'analyse informatique du signal transmis permet d'établir les images des organes internes.



Figure 63 : Image IRM

B.1.3. Image nucléaire

Il existe différentes techniques de médecine nucléaire. Elles se différencient par leur mode d'acquisition et l'élément radioactif mesuré. La Tomoscintigraphie, par exemple mesure les rayonnements, utilisée pour la détection des lésions cérébrales, l'image Scintigraphique peut s'avérer plus efficace que la Scanographique ou par résonance magnétique notamment dans les tumeurs récurrentes.




Figure 64 : Image nucléaire

B.2. Images satellitaires

Une image satellitaire est une représentation graphique, en vue de dessus, d'une zone assez vaste de la terre. Sa particularité est qu'elle est prise par un satellite placé en orbite autour de la planète. C'est une image numérique, traitée par outil informatique, élaborée à partir des signaux transmis par un satellite.

Chaque pixel de l'image numérique est caractérisé par un niveau de gris ou de couleur prélevé à l'emplacement correspondant dans l'image réelle.

En cinquante ans d'histoire spatiale, plusieurs milliers de satellites artificiels ont été lancés et mis en orbite autour de la Terre. Environ trois cents d'entre eux sont actuellement fonctionnels à diverses altitudes. Beaucoup sont utilisés pour les télécommunications, d'autres permettent une observation de notre planète.

Les satellites embarquent divers instruments de mesure : radiomètres, capteurs de température, appareils pouvant mesurer la hauteur des reliefs, la quantité de vapeur d'eau dans l'atmosphère. Grâce aux radiomètres, ils peuvent mesurer la lumière réfléchiée par la surface terrestre dans plusieurs domaines de longueurs d'ondes.

Nous pouvons citer à titre d'exemple les deux types de satellites suivants :

B.2.1. Les satellites à défilement

Ils survolent en une journée des régions très variées, puisque l'orbite est presque fixe, alors que la terre effectue une révolution

Parmi ces satellites, on trouve les satellites *NOAA* (National Oceanic and Atmospheric Administration) qui sont destinés à fournir des images de bonne résolution spatiale (1 km environ) dans le visible et le proche infrarouge d'une part, l'infrarouge thermique d'une autre part, ainsi que le satellite *SPOT* (System Probatoire d'Observation de la Terre), conçu pour fournir avec une très grande résolution spatiale, des données visibles ou proche infrarouge.

B.2.2. Les satellites géostationnaires

Ces satellites regardent toujours la même région de la surface de la terre (environ un quart), ils ont donc une orbite géostationnaire. Ils ont une altitude d'environ 36000 Km et se déplaçant à une vitesse qui correspond à celle de la terre, donnant ainsi l'impression qu'ils sont stationnaires.

Parmi ces satellites, on peut citer les satellites météorologiques *METEOSAT* de première et seconde génération.

B.3. Images METEOSAT

Nous allons d'abord présenter les satellites *MATEOSAT* de première et de seconde génération, puis nous passerons aux procédures utilisées pour former les images de ce type de satellite.

B.3.1. METEOSAT de première génération

Le satellite *METEOSAT* de première génération est un satellite météorologique géostationnaire européen situé à environ 36000Km d'altitude au-dessus de l'équateur. Le champ visuel couvre l'Afrique, l'Europe et les extrémités de l'Asie et de l'Amérique méridionale. L'objectif principal du système *METEOSAT* est la fourniture des données satellitaires rentables et de services annexes correspondant aux besoins des états membres d'*EUMETSAT*. Dans la mesure du possible, le système répond aux besoins exprimés par l'Organisation Météorologique Mondiale.

Il offre ses services à tous les pays du monde capables de recevoir les données. L'Algérie en fait partie (ONM), et joue par conséquent un rôle international. Les données sont dédiées principalement aux besoins de la météorologie opérationnelle, en insistant sur l'assistance à la prévision quotidienne du temps. Cependant, les données sont utiles également pour tous les secteurs de la météorologie, y compris la météorologie marine, l'agro-météorologie et la météorologie aéronautique, ainsi que pour beaucoup d'autres disciplines, en particulier la climatologie et la surveillance de la planète terre.

Dans la famille des satellites METEOSAT de première génération, on trouve sept satellites (de METEOSAT-1 à METEOSAT-7).

Le principal instrument de ce satellite est le radiomètre MVIRI, sa résolution spectrale est de trois canaux spectraux : le canal visible, infrarouge et le canal à vapeur d'eau.

Finalement la résolution temporelle est commune pour tous ces canaux, car elle est relative à la vitesse du capteur (radiomètre) MVIRI, qui est de 30 minutes c'est-à-dire chaque trente minutes, le satellite nous fournit trois types d'images numériques de tailles 2500×2500 pixels pour les canaux infrarouge et vapeur d'eau, de taille 5000×5000 pixels pour le canal visible.

B.3.2. METEOSAT de seconde génération

Le satellite MSG-1 a été mis en place pour assurer la relève de METEOSAT première génération. Il permet d'avoir une amélioration de l'imagerie et une analyse des masses d'air. Il est lancé en orbite au-dessus de l'équateur à 3.5° W. Les deux instruments principaux de ce satellite sont le radiomètre SEVIRI (Spinning Enhanced Visible and InfraRed Image) et GERB (Geostationary Earth Radiation Budget Experiment). Le radiomètre SEVIRI fournit une image l'hémisphère observée par le satellite dans douze bandes (canaux) spectrales différentes du spectre visible et infrarouge, soit quatre fois plus que METEOSAT de première génération.

Finalement, la résolution temporelle est de quinze minutes, c'est-à-dire chaque quinze minutes le satellite nous fournit douze images numériques différentes.

Bibliographies

- [1]: M. GONZALES, R.C. WINTZ: « *Digital image processing*, Addison-Wesley, 1977.
- [2]: AKROUR Nawal, CHAIBI Lilia : « *Bioseg : une plateforme évolutive pour le développement d'approches biomimétiques en segmentation d'images* », E.S.I, Algérie, 2009.
- [3] : BENAMROUZ Said, KETTANE Siham : « *Segmentation d'images par les méthodes adaptatives basées sur les matrices de cooccurrences* », UMMTO, Algérie, 2008/2009.
- [4]: BEN YALLOUL Anis, BEN SALEM Said Eddine: « *Méthodes biomimétiques pour la segmentation d'images* », I.N.I, Algérie, 2006/2007.
- [5] : LAKHDARI Mohamed : « *Segmentation d'images par contour actif en appliquant les algorithmes génétiques* », I.N.I, Algérie, 2008.
- [6] : SLIM Samir : « *Environnement de segmentation d'images à base d'une approche biomimétique hybride* », E.N.I, Algérie, 2007/2008.
- [7] : [//www.kaddour.com/chap1/chap1.html](http://www.kaddour.com/chap1/chap1.html).
- [8] : BELHAMRA Hadjira, MELZI Soumia : « *La segmentation d'images par croissance de régions* », E.S.I. Algérie, 2009/2010.
- [9] : LECOEUR Jérémy, BARILLOT Christain : « *Segmentation d'images cérébrales : Etat de l'art* », IRISA, Campus Universitaire de Baulieu, 35042 Rennes Cedex (France), Rapport de recherche n°6306, version 3, version révisée Février 2008.
- [10]: NAKIB. Amir: « *Conception de méta-heuristiques d'optimisation pour la segmentation d'images: application à des images médicales* », Thèse de Doctorat de l'université de Paris 12, VAL DE MERNE, Décembre, 2007.
- [11]: FELICIA S. JONES: « *Medical image segmentation* », Master of Science, Athens, Georgia, 2003.
- [12]: SEBARI Iman et HE Dong-Chen: « *Les approches de segmentation par coopération région-contour* », Université de Sherbrooke, Québec, Canada, 2010.
- [13] : A. Jain, R. Duin et J. Mao : « *Statistical Pattern Recognition* », IEEE, Vol 22, n°1, Pages (4-37), 2000.

Bibliographie

- [14] : JAIN. A. K, MURTY. M. N, and FLYNN P.J : « *Data Clustering* », Review, ACM Computing Surveys, 1999.
- [15] : CHAMI Djazia : « *Une plate-forme orientée agent pour le data mining* », Université Hadj Lakhdar – Batna, Algérie, 2009/2010.
- [16] : MONMARCHE Nicolas : « *Algorithmes de fourmis artificielles : application à la classification et l'optimisation* », Université de Tours, Doctorat, 20/11/2000.
- [17] : ANDREY P : « *Segmentation d'images par algorithmes génétiques* », thèse de Doctorat, université de Paris 7, Décembre 1997, France.
- [18]: BHANU B, LEE S, et DAS S: « *Adaptive image segmentation using genetic and hybrid search methods* ». IEEE Trans on Aerospace and Electronic System, Volume 31, 1995.
- [19]: HOLLAND. J: « *Adaptation in Natural and Artificial* », University of Michigan Press, 1975.
- [20]: GOLDBERG. D: « *Genetic algorithms in search optimization and machine learning*», Addison, Wesley, 1989.
- [21]: LASSOUAOUI Nadia, HAMAMI Latifa, NOUALI Nadia « *Les Algorithmes Génétiques : application à la segmentation des images* »,Division Informatique mobile Centre de Recherche sur l'Information Scientifique et Technique ; Ecole Nationale Polytechnique, Laboratoire Signal & Communications, Algérie,2004.
- [22]: KENNEDY. J and EBERHART. R.C: « *Particle Swarm optimization* », IEEE. Conference on Neuronal Networks, Pages (1942-1948), Volume 4, October 1995, Piscataway, Japan.
- [23]: KHOUADJIA. M, KHANFOUF. H, MESHOUL. S: « *Une approche adaptative pour la segmentation d'images: Implémentation sur la plate-forme Multi agents NetLoge* », Equipe vision et infrarouge, Laboratoire LIRE, Université Mentouri, Constantine, Algérie.
- [24]: DJEMAME Safia, BATOUCHE Mohammed : « *Une approche biomimétique pour la segmentation d'images : Inspiration des Araignées Sociales* », Université Ferhat Abbes, Sétif, Algérie.
- [25] : OUADFEL Salima : « *Segmentation d'images basée sur la résolution collective par colonies de fourmis artificielles* », Doctorat, Université Hadj Lakhdar, Batna, Algérie.

Bibliographie

- [26] : FORTHOFFER Martiral, GIROD Jean Pierre et BREMONT Jacques : « *Edge Detection Using Wavelet Transform and Neural Networks* », Traitement du signal, volume 8, n° 6, 1999.
- [27] : ABASSENE.A, MASHOUL. S, BETOUCHE. M : « *Segmentation d'images par émergence basée sur les automates cellulaires évolutionnaires* », Université Mentouri de Constantine, Algérie.
- [28]: VERONICA Anna, BATERINA, CARLOS.M. OPPUS: « *An Ant Colony Optimization Algorithm For Image Edge Detection* », University Katipunan Avenue, Loyola Heights, Quezon City PHILIPPINES Issue 2 , Volume 4, 2010.
- [29] : MONMARCHE Nicolas et LANOIR Alain : « *Des fourmis réelles aux fourmis artificielles : Deux exemples d'approches biomimétiques de la résolution de problèmes en informatique* », Institut de Recherche sur la biologie de l'Insecte, sixième journée CASCIMODOT, Université de Tours, France, Juillet 2007.
- [30]: DENEBOURG. J.L, ARON.S, GOSS. S, et PASTEELS. J.M: « *The self-organizing exploratory pattern of the argentine ant* », Journal: An Insect Behavior, Pages (159-168), 1990.
- [31]: DREO. J, PETROWSKI. A, SIARRY. P et TAILLARD. E : « *Méta heuristiques pour l'optimisation difficile* », Eyrolles, 2003.
- [32]: BLUM. C: « *Ant colony optimization: Introduction and recent trends* », Physics of Life Reviews, Volume 2, pages(353-373), 2005.
- [33]: DRIGO. M, STUTZLE. T: « *Ant Colony Optimization* », MIT Press, Cambridge, USA, 2004.
- [33]: JING Tian, WEIYU Yu, and SHENGLI Xie: « *An Ant Colony Optimization Algorithm For Image Edge Detection* », IEEE, 2008.