



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

MEMOIRE DE MAGISTER

Présenté par :

HOCINI Lotfi

En vue de l'obtention du diplôme de Magister en Electronique

Option télédétection

Intitulé :

Conception de métaheuristiques d'optimisation pour la segmentation des images de télédétection

Devant le jury d'examen composé de :

Mr. DIAF Moussa	Professeur à l'UMMTO	Président
Mr. AMEUR Soltane	Professeur à l'UMMTO	Rapporteur
Mme. AMEUR Zohra	M. C. A. à l'UMMTO	Examinatrice
Mr. LAHDIR Mourad	M. C. A. à l'UMMTO	Examineur
Mr. HADDAB Salah	M. C. A. à l'UMMTO	Examineur

Soutenu le : 14/11/2012

REMERCIEMENTS

Ce travail a été effectué au sein du *Laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires (LAMPA)*, de l'université Mouloud Mammeri de Tizi Ouzou. Il n'aurait pu aboutir sans l'aide de plusieurs personnes, que je ne remercierai jamais assez.

Mes vifs remerciements vont tous d'abord à mon directeur de mémoire : Mr. Soltane AMEUR, professeur à l'UMMTO, pour son encadrement sans faille, sa disponibilité et sa rigueur lors de la direction de ce travail.

J'exprime ma reconnaissance à Mr. Moussa DIAF, Professeur à l'UMMTO, qui m'a fait l'honneur de présider le jury d'examen de ce mémoire.

Mes sincères remerciements à Mme. Zohra AMEUR, Mr. Mourad LAHDIR Mr. Salah HADDAB, Maitres de conférences (A) à l'UMMTO, qui ont marqué leur intérêt pour mon travail en acceptant de l'examiner.

Mes remerciements vont aussi au Professeur Patrick SIARRY et Hamouche OULHADJ (Maître de conférences) du *Laboratoire Images, Signaux & Systèmes Intelligents* de l'université PARIS-EST CRETEIL, France, de m'avoir proposé la thématique de ce mémoire ainsi que pour les précieux conseils qu'ils m'ont prodigués tout le long de ce travail.

Je ne saurai terminer sans remercier toute ma famille et tous ceux qui ont, de près ou de loin, aidé à rendre ce travail possible, que ce soit par des idées ou par des encouragements.

SOMMAIRE

Introduction générale	1
------------------------------------	---

Chapitre 1 : télédétection et approches de segmentation d'image

1.1 Introduction	4
1.2 Les approches de segmentation d'images	4
1.2.1 Approches contours	4
1.2.2 Segmentation par seuillage	5
1.2.3 Approches régions	7
1.2.3.1 Méthodes par division (top-down)	7
1.2.3.2 Méthodes par fusion (bottom-up)	8
1.2.3.3 Méthodes par division / fusion (split and merge)	9
1.2.4 Segmentation par classification	9
1.2.4.1 Les réseaux de neurones artificiels	9
1.2.4.2 Les k-means	10
1.2.4.3 Les c-means floues	10
1.3 La télédétection	11
1.3.1 Processus de télédétection	11
1.3.2 Les satellites de télédétection	13
1.3.2.1 Les satellites Meteosat Seconde Génération	13
1.3.2.1.1 Les canaux visibles	15
1.3.2.1.2 Les canaux vapeur d'eau	15
1.3.2.1.3 Les canaux infrarouges	16
1.3.2.2 Les satellites SPOT	17
1.4 Conclusion	21

Chapitre 2 : métaheuristiques d'optimisation

2.1 Introduction	23
2.2 Problèmes d'optimisation	23

2.2.1 Optimisation mono objectif	23
2.2.2 Optimisation multi objectif	24
2.2.3 Différentes approches de résolution de problème multiobjectif	25
2.2.3.1 Approche agrégative	25
2.2.3.2 Approche non agrégative	26
2.2.3.3 Approche Pareto	27
2.3 Optimisation difficile	27
2.4 Les métaheuristiques	28
2.4.1 Le recuit simulé	28
2.4.1.1 Algorithme de Metropolis	29
2.4.1.2 Algorithme du recuit simulé	29
2.4.2 Algorithmes de colonies de fourmis	30
2.4.3 Algorithmes génétiques	33
2.4.3.1 Operateur de sélection pour reproduction	34
2.4.3.2 Operateurs de diversification	36
2.4.3.3 Operateurs de remplacement	37
2.5 Métaheuristiques en segmentation d'images	38
2.6 Conclusion	39

Chapitre 3 : application des algorithmes génétiques pour la segmentation d'images

3.1 Introduction	41
3.2 Reformulation du problème de segmentation d'images en un problème d'optimisation ..	41
3.3 Application des algorithmes génétiques pour la segmentation d'images en monoobjectif.	43
3.3.1 Extraction d'attributs texturaux par matrices de cooccurrences	43
3.3.1.1 Principe	44
3.3.1.2 Les attributs texturaux	44
3.3.1.3 La requantification	46
3.3.2 Classification des pixels	47
3.3.2.1 Population initiale	48
3.3.2.2 Sélections pour la reproduction	48

3.3.2.3 Croisement des individus	49
3.3.2.4 Mutation d'un individu	49
3.3.2.5 Sélections pour le remplacement	49
3.3.2.6 Critère d'arrêt	49
3.3.2.7 Segmentation	50
3.3 Application des algorithmes génétiques pour la segmentation multicritère d'images	50
3.3.1 Sélections pour la reproduction	50
3.3.2 Sélections pour le remplacement	51
3.3.3 Segmentation	52
3.4 Conclusion	52

Chapitre 4 : Applications et discussions

4.1 Introduction	54
4.2 Application sur des images test issues de l'album de Brodatz et de la base VisTex.....	54
4.2.1 Extractions des attributs de textures	55
4.2.2 Choix des attributs de textures.....	57
4.2.3 Extraction de l'information spectrale	57
4.2.4 Résultats de segmentation	57
4.2.5 Discussion	62
4.2.6 Évaluation des résultats	62
4.2.7 Discussion	64
4.3 Application sur les images de télédétection	64
4.3.1 Application sur les images MSG	64
4.3.2 Discussion	66
4.3.3 Application sur les images SPOT	66
4.3.4 Discussion	68
4.4 Conclusion	68
Conclusion et perspectives	70

Annexes

Bibliographie

INTRODUCTION GENERALE

INTRODUCTION GENERALE

Les satellites de télédétection fournissent régulièrement des images de la terre et de l'atmosphère de plus en plus nombreuses et de plus en plus riches. La télédétection est devenue ainsi une discipline très importante, car elle est désormais un outil d'aide à la décision très précieux et indispensable pour la gestion et la protection des ressources terrestres. L'analyse et l'interprétation de ces images de télédétection constituent un champ important de recherche et d'études scientifiques. Plusieurs applications en tirent profit, par exemple, la météorologie, le suivi de la déforestation, l'évolution de la désertification, l'évolution des ressources en eau, la cartographie de l'occupation du sol, l'inventaire des ressources agricoles, la construction et la mise à jour des cartes topographiques, la découverte des maladies des forêts, la localisation des zones de pollution, de végétation, d'industrie, etc.

L'étape d'analyse est souvent confondue avec une étape de segmentation qui consiste à partitionner une image en des régions à caractéristiques visuelles similaires. Toutefois, une méthode de segmentation idéale n'existe pas, il est de même pour un critère unique de segmentation. Une bonne segmentation est donc, celle qui permet de fournir les meilleures informations pour l'étape d'interprétation.

Les métaheuristiques d'optimisation sont des algorithmes généraux d'optimisation applicables sur une large variété de problèmes. Ils sont apparus au début des années quatre-vingt afin de résoudre des problèmes où les algorithmes classiques sont incapables. Parmi les métaheuristiques les plus connues, on trouve : les algorithmes génétiques, les colonies de fourmis, l'essaim particulaire, et le recuit simulé, etc.

Dans le présent mémoire, nous nous sommes intéressés à la segmentation d'images optiques de télédétections, à savoir des images Meteosat Seconde Génération et des images SPOT. Pour cela, deux approches ont été proposées : une approche basée sur l'algorithme

génétique monoobjectif qui utilise l'inertie intraclasse pour caractériser une bonne segmentation (classification), et une autre approche utilisant les algorithmes génétiques multiobjectif qui font intervenir en parallèle deux critères de segmentation (l'inertie intraclasse-longueur du contour, et l'inertie intraclasse-connectivité des pixels).

Dans le premier chapitre de ce travail, nous présenterons les différentes approches de segmentation d'images ainsi qu'un aperçu sur la télédétection, les satellites Météosat seconde génération et SPOT dont les données seront utilisées lors des différentes applications.

Le deuxième chapitre est consacré aux problèmes d'optimisation monoobjectif et multiobjectif ainsi qu'aux méthodes de résolution par métaheuristiques d'optimisation.

Le troisième chapitre porte sur l'adaptation des algorithmes génétiques au problème de segmentation d'images. Pour ce faire, nous reformulerons le problème de segmentation, dans un premier temps, en un problème d'optimisation monoobjectif, puis dans un deuxième temps, en problème multiobjectif.

Les résultats expérimentaux sont représentés et discutés dans le quatrième chapitre. Un tableau comparatif des résultats obtenus avec les différentes applications ainsi que les k-means a été donné.

Enfin, dans la conclusion générale de ce manuscrit, nous récapitulerons notre contribution et avancerons quelques perspectives ouvertes.

CHAPITRE 1

TELEDETECTION ET APPROCHES DE SEGMENTATION D'IMAGES

CHAPITRE 1

TELEDETECTION ET APPROCHES DE SEGMENTATION D'IMAGES

1.1 INTRODUCTION

La segmentation d'images est généralement définie comme étant un processus de partitionnement d'une image en groupes homogènes tel que chaque région soit homogène et l'union de deux régions adjacentes n'est pas homogène [1]. C'est un vaste sujet d'étude et fait partie des grands thèmes de l'imagerie numérique.

La première partie de ce chapitre est consacrée à la présentation de diverses techniques connues de segmentation d'images, organisées selon l'approche qui les régie. Dans la deuxième, nous avons décrit les données de téledétection sur lesquelles sont appliquées les méthodes de segmentation par métaheuristiques proposées dans ce travail.

1.2 LES APPROCHES DE SEGMENTATION D'IMAGES

Il n'existe pas qu'une seule manière de catégoriser les méthodes de segmentation d'images. Shankar [2] les a classées en quatre classes : a) Approche par contours b) Approche Pixels c) Approche régions d) Approche hybride. Ameer [3] en deux classes principales: Approche frontières et approche régions. Guo [4], aussi en deux classes : couleur et texture. Un papier récent [5] illustre mieux l'ensemble des différentes classifications présentes dans la littérature.

1.2.1 APPROCHES CONTOURS

De façon général, un contour est défini comme étant la frontière entre deux régions, la détection du contour est équivalente à la détection de la discontinuité entre ces deux régions. Les approches contour opèrent à trouver les zones de variations significatives d'intensité lumineuse (niveaux de gris) ou de couleur dans l'image. Nous pouvons citer les approches se basant sur les différences finies comme l'opérateur de gradient, l'opérateur Laplacien et les

différents filtres à savoir : le filtre de Sobel, Prewitt et Roberts ou bien des approches analytiques comme le filtre de Canny [6]. Mais ce genre de techniques est peu exploitable car elles donnent souvent des contours non fermés, bruités ou non détectés ; une utilisation des propriétés des régions comprise entre ces contours pourrait nettement améliorer la détection de ce derniers [7]. La figure 1.1 illustre les résultats obtenus avec quelques filtres.



Figure 1.1 : Illustration de détection de contours, a- Image Lenna originale ; b- Détection de contours par filtre de Sobel ; c- Détection de contours par filtre de Prewitt ; d- Détection de contours par filtre de Roberts; e- Détection de contours par filtre de Canny

1.2.2 SEGMENTATION PAR SEUILLAGE

Dans beaucoup d'applications de traitement d'images, on considère que les niveaux de gris des pixels appartenant à un objet sont relativement différents de ceux du fond [8] [9] [5]. Le seuillage est une technique simple et efficace pour séparer les objets du fond. Toutefois, la difficulté apparaît dans le choix des seuils optimaux pour une séparation optimale.

Soit ' I ' l'image originale et ' I_s ' l'image segmentée. Segmenter I en N classes revient à chercher $N-1$ seuils. La classification de chaque pixel est définie comme suit :

$$I_s(x,y) = k \text{ si } S_k \leq I(x,y) < S_{k+1} \quad \text{pour } k = 0, \dots, N$$


Où x, y sont les coordonnées du pixel ; S_0, \dots, S_N sont les différents seuils de segmentation.

A titre d'exemple, nous allons présenter un seuillage manuel qui comporte quatre étapes :

1. Observation de l'histogramme de l'image
2. Choix des seuils dans les vallées
3. Définition des classes de régions par intervalle de couleurs
4. Classification des pixels



(a)



(b)



(c)

Figure 1.2 : Exemple de seuillage manuel de l'image Lenna. (a) Image originale ; (b) Histogramme de l'image ; (c) Seuillage en 5 classes ($S_{1,6} = 0, 70, 113, 136, 185, 255$)

Dans la littérature, on y trouve plusieurs classifications des méthodes de segmentation par seuillage [9] [10] [11]. Les auteurs les ont classées en deux catégories :

- Les méthodes non paramétriques : qui ont la réputation d'être robustes ; elles sont basées sur l'optimisation d'un ou plusieurs critères comme, par exemple, maximiser la variance interclasse. La plus connue d'entre elles est la méthode d'Otsu [10].
- Les méthodes paramétriques : qui sont basées sur l'hypothèse que les densités de probabilité des niveaux de gris des différentes classes sont gaussiennes, une approximation de l'histogramme de l'image à traiter par une combinaison linéaire de gaussiennes est toujours effectuée avant l'opération de seuillage, ou les seuils optimaux sont à l'intersection de ces dernières [9]

1.2.3 APPROCHES REGIONS :

Ce sont des approches utilisant des techniques d'identification et de localisation d'ensembles connexes de pixels ayant des propriétés similaires. Parmi elles, on distingue :

1.2.3.1 METHODES PAR DEVISION (Top-Down)

Ce sont des Méthodes qui opèrent en découpant l'image principale en régions plus petites suivant un critère d'hétérogénéité. Le découpage s'arrête quand il n'y a plus de régions inhomogènes [12]. La méthode Quadtree est souvent utilisée pour réaliser ce découpage (voir Figure 3). Il s'agit d'une décomposition récursive en quatre sous régions carrées des régions hétérogènes en commençant par l'image entière qui est de taille $N \times N$, où $N = 2^n$. La figure 1.4 illustre un exemple de résultat de découpage obtenu avec cette méthode.




Figure 1.3 : Principe de division de région. (a) Décomposition de l'image en blocs ; (b) Diagramme hiérarchique de la décomposition.

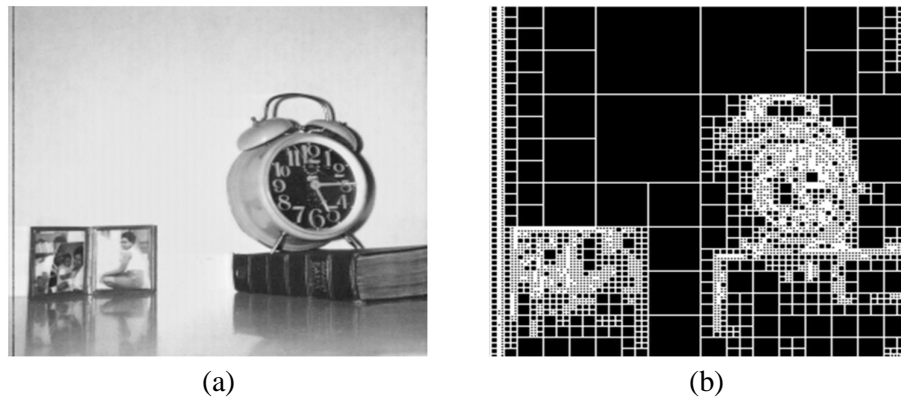


Figure 1.4 : Exemple de résultat obtenu par la méthode de division des régions. (a) Image Clock originale ; (b) Blocs de dévision obtenus

1.2.3.2 METHODES PAR FUSION (Bottom-Up)

Ces méthodes opèrent en regroupant des pixels ou des groupes de pixels selon un critère d'homogénéité pour obtenir un ensemble de régions homogènes [12]. Elles suivent une hiérarchie arborescente comme montrée dans la figure 1.5. Leurs inconvénients majeurs c'est que le résultat final (image segmentée) dépend fortement du choix des régions de départ.




Figure 1.5 : Hiérarchie de la méthode de segmentation par fusion

1.2.3.3 METHODES PAR DIVISION / FUSION (Split and Merge)

Proposées par Horwitz [13], elles réunissent l'ensemble des algorithmes utilisés dans les techniques précédemment citées (méthodes par fusion et méthodes par division). Le processus de segmentation se déroule en deux étapes : la division en blocs (régions) suivant un critère d'hétérogénéité est effectuée en premier lieu ; puis, suit l'étape de fusion où toutes les régions adjacentes qui découlent de l'étape de division et vérifiant une heuristique d'homogénéité sont regroupées.

1.2.4 SEGMENTATION PAR CLASSIFICATION

Elle consiste à regrouper en sous-ensembles (Clusters, en Anglais) des pixels ayant des propriétés proches. Selon une intervention humaine ou non, on les classes en deux catégories :

- Classification supervisée, citons, par exemple, les réseaux de neurones artificiels
- Classification non supervisée, comme la méthode des K-means, C-means flous.

1.2.4.1 LES RESEAUX DE NEURONES ARTIFICIELS

La structure d'un neurone artificiel est illustrée dans la figure 1.6. Les blocs rectangulaires représentent les entrées multipliées par des poids W_i , F correspond à la fonction de classification (de segmentation) et z correspond à la somme linéaire des poids multipliés par les entrées correspondantes. Un réseau peut être créé en augmentant le nombre de neurones et de sorties avec l'ajout de blocs elliptiques ($F(z)$) horizontalement et verticalement [5].




Figure 1.6 : Structure d'un neurone

En segmentation d'images, les réseaux de neurones sont utilisés comme classifieurs [14]. Les poids W_i sont déterminés par apprentissage sur une base de d'images dont les résultats de segmentations sont connus.

L'une des applications des réseaux de neurones en segmentation d'images de télédétection est faite par Visa [15]. Ils ont injecté comme entrées, des vecteurs d'attributs de textures extraits à partir des matrices de cooccurrences à un réseau de neurones SOM (self-organizing-map) dans le but d'estimer la couverture nuageuse.

1.2.4.2 LES K-MEANS

L'algorithme K-Means (centres mobiles) est l'un des algorithmes de clustering les plus connus, il a été mis au point par MacQueen à la fin des années soixante [16]. Il est basé sur la méthode des centroïdes (ou centres de gravité). Le principe de cette méthode est le suivant :

On choisit arbitrairement k centres : c_1, \dots, c_k où chaque c_i représente le centre d'une classe C_i . Chaque classe C_i est représentée par un ensemble d'individus plus proches de c_i que de tout autre centre. Après cette initialisation, on effectue une deuxième partition en regroupant les individus autour des \bar{x}_i qui prennent alors la place des c_i (\bar{x}_i est le centre de gravité de la classe C_i , calculé en utilisant les nouvelles classes obtenues). Le processus est ainsi réitéré jusqu'à atteindre un état de stabilité où aucune amélioration n'est possible.

Le critère optimisé par cet algorithme (K-Means) est défini par la relation (1.1).

$$\text{minimum } D_T(C) = \sum_{i=1}^k \sum_{j=1}^{Q_i} d(x_j^{(i)}, \bar{x}_i)^2 \quad (1.1)$$

Où $D_T(C)$ désigne la distorsion totale (appelée aussi, erreur quadratique), k le nombre de classe ; Q_i , le nombre d'objets de la classe i ; d , la distance entre le point $x_j^{(i)}$ appartenant à la classe i et le centre de gravité \bar{x}_i de cette classe.

Cette méthode est convergente et surtout avantageuse du point de vue calcul mais elle dépend essentiellement de la partition initiale. Il existe donc un risque d'obtenir une partition qui ne soit pas optimale mais seulement meilleure que la partition initiale. De plus, la définition de la classe se fait à partir de son centre, qui pourrait ne pas être un individu de l'ensemble à classer, d'où le risque d'obtenir des classes vides [17].

1.2.4.3 LES C-MEANS FLOUES

L'algorithme des C-Means flous (Fuzzy C-Means en anglais) introduit par Dunn [18] au début des années soixante-dix généralise l'algorithme des K-Means en permettant la

classification floue basées sur la théorie des ensembles flous [19]. Dans le cas des C-Means flous, la fonction à minimiser est donnée par la relation suivante :

$$J_m(C) = \sum_{q=1}^Q \sum_{k=1}^k \mu_{qk}^m d_{qk}^2 \quad 1 < m < \infty \quad (1.2)$$

Où m est le facteur flou et d_{qk} la distance séparant l'objet x_q du centre \bar{x}_k de la classe k . la mise à jour est donnée par l'expression suivante :

$$\bar{x}_k = \frac{\sum_{q=1}^Q \mu_{qk}^m x_q}{\sum_{q=1}^Q \mu_{qk}^m} \quad (1.3)$$

La mise à jour des centres des classes modifie la répartition des objets, par conséquent, une mise à jour de la matrice d'appartenance est nécessaire. Elle est effectuée en utilisant l'expression qui suit :

$$\mu_{qk} = \frac{1}{\sum_{j=1}^k \left(\frac{d_{qk}}{d_{qj}} \right)^{2/m-1}} \quad (1.4)$$

Avec $\mu_{qk} = 1$ si $d_{qk} = 0$ et $\mu_{qk} = 0$ pour $j \neq \frac{k}{d_{qk}} = 0$

1.3 LA TELEDETECTION

La téledétection est la technique qui, par l'acquisition d'images, permet d'obtenir de l'information sur la surface de la Terre sans contact direct avec celle-ci. Elle englobe tout le processus qui consiste à capter et à enregistrer l'énergie d'un rayonnement électromagnétique émis ou réfléchi, à traiter et à analyser l'information, pour ensuite mettre en application cette information.

1.3.1 PROCESSUS DE TELEDETECTION

Durant le processus de téledétection, le rayonnement passe par sept étapes principales [20]:

1. Source d'énergie ou d'illumination: à l'origine du processus de téledétection se trouve généralement une source d'énergie pour illuminer la cible. Ce n'est pas nécessaire, par exemple, dans le cas de l'infrarouge thermique où la cible

émet elle-même son rayonnement. La source et les capteurs sont parfois confondus; il s'agit alors de capteurs actifs, tels que le Radar, qui envoient un signal sur la cible et en capte la partie réfléchi.

2. Atmosphère: durant son parcours entre la source d'énergie et la cible, le rayonnement interagit avec l'atmosphère. Une seconde interaction se produit lors du trajet retour entre la cible et le capteur
3. Cible: une fois arrivée à la cible, l'énergie interagit avec celle ci. La nature de cette interaction dépend des caractéristiques du rayonnement et des propriétés de la surface. Par exemple, la surface lisse de l'eau en absence de vague est un réflecteur spéculaire des ondes radar: presque aucune information n'est retransmise au capteur et l'eau apparaît donc très sombre sur les images radar.
4. Enregistrement de l'énergie par le capteur: une fois l'énergie diffusée ou émise par la cible, elle est captée à distance pour être enregistrée.
5. Transmission, réception et traitement: l'énergie enregistrée par le capteur est transmise à une station de réception où l'information est transformée en images.

Les images de télédétection sont composées d'une ou plusieurs bandes spectrales (ou canal) correspondant aux différentes longueurs d'onde captées. Une image en couleurs naturelles contient trois bandes spectrales dans les longueurs d'onde du rouge, du vert et du bleu. Une image est dite en panchromatique lorsqu'un seul canal contient l'information de tout le spectre visible. Pour visualiser des réflectances émises dans des longueurs d'onde non visibles à l'œil, on peut utiliser l'une des trois couleurs primaires. Par exemple, les images en fausses couleurs ou infrarouge couleur (IRC) contiennent du proche infrarouge, généralement représenté par la couleur rouge. Le rouge est alors codé en vert et le vert en bleu.

6. Interprétation et analyse : une interprétation visuelle et/ou numérique de l'image traitée est ensuite nécessaire pour extraire l'information que l'on désire obtenir sur la cible.
7. Application : la dernière étape du processus consiste à utiliser l'information extraite de l'image pour mieux comprendre la cible, pour nous en faire découvrir de nouveaux aspects ou pour aider à résoudre un problème particulier.

1.3.2 LES SATELLITES DE TELEDETECTION

Ce sont des satellites qui observent la Terre, dans un but scientifique (température de la mer, manteau neigeux, sécheresse, ...), économique (ressources naturelles, agriculture, ...) ou militaire (rôle majeur dans les guerres). Le spectre d'observation est vaste : optique, radar, infrarouge, ultraviolet, écoute de signaux radioélectriques... Citons quelques satellites de cette famille :

- SPOT pour observer le sol terrestre ;
- METEOSAT pour la météorologie ;
- CRYOSAT-2 pour mesurer l'épaisseur et la circonférence des calottes polaires et de la banquise.

En vue des images sur lesquelles nous souhaitons travailler, nous ne présentons que les satellites METEOSAT SECONDE GENERATION et SPOT.

1.3.2.1 LES SATELLITES METEOSAT SECONDE GENERATION

Les satellites METEOSAT seconde génération sont des satellites météorologiques géostationnaires européens. L'objectif principal du système METEOSAT est la fourniture de données satellitaires rentables et de services annexes correspondant aux besoins des Etats membres d'EUMETSAT. Dans la mesure du possible, le système répond aux besoins exprimés par l'Organisation Météorologique Mondiale.

Le programme MSG (METEOSAT Seconde Génération) a été mis en place pour assurer la relève de METEOSAT première génération. Il permet d'avoir une amélioration de l'imagerie et d'analyser les masses d'air. Le premier satellite METEOSAT Seconde Génération (MSG-1 ou encore, METEOSAT-8) (Fig.1.11) a été lancé le 28 août 2002. Il est positionné au-dessus de l'équateur à 3.5°W. Il n'est devenu pleinement opérationnel qu'à partir du 29 janvier 2004.

Les deux instruments principaux du satellite sont les radiomètres SEVIRI (Spinning Enhanced Visible and InfraRed Imager) et GERB (Geostationary Earth Radiation Budget experiment). L'imageur SEVIRI fournit toutes les 15 minutes une image de l'hémisphère observée par le satellite dans 12 bandes spectrales (Tableau 1.1) différentes du spectre visible et infrarouge. Cet enrichissement du spectre des observations représente une avancée majeure pour l'amélioration des modèles météorologiques numériques. En réduisant à 15 minutes le

rafraîchissement des données, MSG-1 permet aux climatologues et aux météorologues de déceler plus facilement le déclenchement des phénomènes à évolution rapide, comme les orages, les tempêtes de neige ou les bancs de brouillard. De même, une résolution au sol de 1 km dans le spectre visible au lieu de 2,5 km précédemment l'observation et le suivi de phénomènes localisés. Le radiomètre GERB fournit des données essentielles sur le bilan radiatif de la Terre, c'est-à-dire le rapport entre la quantité d'énergie reçue du Soleil par notre planète et la quantité d'énergie rayonnée en retour. Ce bilan radiatif, encore largement mal connu, joue un rôle crucial dans l'équilibre climatique de la planète.

Nom du canal	Longueur d'onde centrale (μm)	Bande spectrale (μm)
VIS 0.6	0.635	0.56 – 0.71
VIS 0.8	0.81	0.74 – 0.88
IR 1.6	1.64	1.50 – 1.78
IR 3.9	3.92	3.48 – 4.36
WV 6.2	6.25	5.35 – 7.15
WV 7.3	7.35	6.85 – 7.85
IR 8.7	8.7	8.30 – 9.10
IR 9.7	9.66	9.38 – 9.94
IR 10.8	10.8	9.80 – 11.80
IR 12.0	12	11.00 – 13.00
IR 13.4	13.4	12.40 – 14.40
HRV	0.7	0.50 – 0.90

Tableau 1.1 : canaux de MSG

Nous présentons dans les paragraphes suivants les différents canaux du radiomètre SEVIRI de MSG.

1.3.2.1.1 LES CANAUX VISIBLES

MSG-1 possède deux canaux visibles : VIS 0.6 et VIS 0.8. Les niveaux de gris des images provenant de ces canaux sont directement liés au pouvoir réfléchissant des surfaces. Ces canaux sont indispensables pour la détection et le suivi des masses nuageuses, la détermination des zones observées lors de prises de vue successives, ainsi que la surveillance de la surface des terres et des aérosols. Leur combinaison permet d'établir des indices de végétation. En effet, les nuages ont un pouvoir réfléchissant élevé. Plus le nuage est réfléchissant, plus le niveau de gris tendra vers le blanc. Ainsi, les océans apparaissent en noir, les continents en gris et les nuages en blanc.




Figure 1.7 : Images du globe prises par MSG-1 dans les canaux visibles ; a- VIS 0.6, b- VIS 0.8

1.3.2.1.2 LES CANAUX VAPEUR D'EAU

MSG-1 possède deux canaux : WV 6.2 et WV 7.3. Ces canaux permettent de mesurer la vapeur d'eau dans la mésosphère, de fournir des traceurs pour les vents atmosphériques et d'affecter une altitude aux nuages semi-transparents.

Les deux canaux séparés permettent d'obtenir des informations sur le contenu en vapeur d'eau à différents niveaux de la troposphère.




Figure 1.8 : Images du globe prises par MSG-1 dans les canaux vapeur d'eau ; a- WV 6.2, b- WV 7.3

1.3.2.1.3 LES CANAUX INFRAROUGES

MSG-1 possède sept canaux dans l'infrarouge dont nous présentons leurs caractéristiques ci-dessous.

Le canal IR 1.6 : Ce canal est situé dans la partie dite proche infrarouge du spectre électromagnétique. Il aide à faire la différence entre surfaces nuageuses et surfaces neigeuses et entre nuages de glace et d'eau. Il apporte aussi des informations sur la présence d'aérosols atmosphériques.

Le canal IR 3.9 : l'interprétation des images provenant de ce canal nécessite quelques précautions. En effet, durant le jour, l'énergie solaire réfléchi domine pour donner l'apparence d'une image dans la partie visible du spectre, tandis que la nuit, l'énergie ne provient que de la Terre avec les caractéristiques de la partie infrarouge du spectre.

Ce canal est utilisé principalement pour la détection des nuages bas, des brouillards nocturnes et des incendies de forêts. Il sert aussi à mesurer les températures à la surface de la Terre et de la mer.


Le canal IR 8.7 : Il apporte essentiellement des informations sur les masses nuageuses minces des cirrus et permet de faire la différence entre les nuages de glace et d'eau.

Le canal IR 9.7 : Ce canal est sensible à la concentration d'ozone dans la partie basse de la stratosphère. Il sert à mesurer l'ozone total et à évaluer sa variabilité diurne. Il peut aussi


servir à établir les configurations d'ozone comme indicateurs des champs de vents à ce niveau.

Les canaux IR 10.8 et IR 12.0 : Ils sont situés dans l'infrarouge thermique. Chaque canal réagit à la température des nuages et de la surface terrestre. Ensemble, ces canaux permettent de réduire les effets atmosphériques en mesurant les températures de la surface de la Terre et du sommet des nuages. Ils servent aussi au suivi des nuages pour déterminer les vents atmosphériques et estimer l'instabilité atmosphérique.


Le canal IR 13.4 : Ce canal est situé dans la partie du spectre où le rayonnement est absorbé par les molécules de dioxyde de carbone (CO₂). Il sert à estimer l'instabilité atmosphérique et contribue à fournir des informations sur la température de la basse troposphère.




(a)




(b)



(c)



(d)



(e)




Figure 1.9 : Images du globe prises par MSG-1 dans les canaux infrarouges ; a- IR 1.6, b- IR 3.9, c- IR 8.7, d-IR 9.7, e- IR 10.8, f- IR 12.0, g- IR 13.4

1.3.2.2 LES SATELITES SPOT

Les satellites SPOT (Système Probatoire d'Observation de la Terre) sont des satellites français de télédétection, conçus pour fournir, avec une très grande résolution spatiale, des données visibles, proche infrarouge et moyen infrarouge (SPOT 4, 5) destinés à la cartographie et aux études thématiques. Le premier satellite SPOT a été mis en orbite le 22 février 1986 par la fusée Ariane-1.

Les satellites Spot sont placés sur une orbite polaire, circulaire, héliosynchrone et phasée par rapport à la Terre. L'inclinaison du plan orbital de 98 degrés et la rotation de la terre autour d'elle-même, permet au satellite de survoler la Terre en tout point au cours d'un cycle de 26 jours à une altitude de 832 km. La période d'une révolution est de 101 minutes, ce qui correspond à $14 + 5/26$ révolution par jour et 369 par cycle.

Le plan orbital forme un angle constant par rapport à la direction du soleil afin que les satellites survolent toujours un point précis à la même heure locale permettant, ainsi, de prendre des images dans des conditions d'éclairage similaires afin de pouvoir comparer des observations d'un point donné prises à différentes dates. Cette orbite est dite héliosynchrone (figure 1.10).




Figure 1.10 : orbite héliosynchrone de Spot

Chaque satellite Spot est constitué de deux instruments optiques identiques, d'enregistreurs de données et d'un système de transmission des images vers des stations de réception au sol. Le satellite Spot 5 emporte en plus un instrument HRS (Haute résolution stéréoscopique) (figure 1.11) pour l'acquisition simultanée de couples d'images stéréoscopiques d'une large fauchée de 120 km (largeur de la scène observée centrée sur la trace du satellite) par 600 km (longueur maximale d'une scène), avec une bande spectrale panchromatique d'une résolution de 10 m (échantillonnage le long de la trace : 5 m). Cette instrument pointe à la fois vers l'avant et vers l'arrière du satellite permettant l'acquisition simultanée des deux images d'un couple stéréoscopique. Lors du même passage du satellite, le télescope avant (angle de visée de 20° par rapport à la verticale) capture les images au sol, suivi, une minute trente secondes plus tard par le télescope arrière (angle de visée de 20° également) qui couvre la même bande de terrain. L'acquisition simultanée des deux images constitue un avantage important pour la qualité et la précision des HRS, le processus automatique de corrélation étant grandement facilité par la parfaite ressemblance radiométrique des deux images.




Figure 1.11 : vision stéréoscopique haute résolution de Spot

Les instruments optiques haute résolution des satellites Spot (HRV - Haute Résolution Visible sur Spot 2 ; HRVIR - Haute Résolution Visible InfraRouge sur Spot 4 et HRG - Haute Résolution Géométrique sur Spot 5), dont les bandes spectrales sont illustrées dans le tableau 1.2, peuvent effectuer des observations obliques, jusqu'à ± 27 degrés de la verticale du satellite. En effet, l'orientation du miroir d'entrée de chaque instrument peut être télécommandée par les stations au sol, permettant ainsi d'observer des régions particulières qui ne sont pas nécessairement à la verticale du satellite. Chaque instrument peut indifféremment acquérir des images mode panchromatique ou multispectral. Les bandes spectrales de chaque instrument sont acquises avec une résolution au sol variable selon le satellite.

Satellite	Spectre électromagnétique	Taille des pixels	Bandes spectrales
Spot 5	Panchromatique	2,5 m ou 5 m	0.48 - 0.71 μm
	B1 : vert	10 m	0.50 - 0.59 μm
	B2 : rouge	10 m	0.61 - 0.68 μm
	B3 : proche infrarouge	10 m	0.78 - 0.89 μm
	B4 : moyen infrarouge (MIR)	20 m	1.58 - 1.75 μm
Spot 4	Monospectral	10 m	0.61 - 0.68 μm
	B1 : vert	20 m	0.50 - 0.59 μm
	B2 : rouge	20 m	0.61 - 0.68 μm
	B3 : proche infrarouge	20 m	0.78 - 0.89 μm
	B4 : moyen infrarouge (MIR)	20 m	1.58 - 1.75 μm
Spot 1	Panchromatique	10 m	0.50 - 0.73 μm
Spot 2	B1 : vert	20 m	0.50 - 0.59 μm
Spot 3	B2 : rouge	20 m	0.61 - 0.68 μm
	B3 : proche infrarouge	20 m	0.78- 0.89 μm

Tableau 1.2 : canaux de SPOT

1.4 CONCLUSION

Dans ce chapitre, nous avons donné un aperçu sur les différentes méthodes de segmentation d'images et avons présenté les images de télédétection utilisées dans ce travail ainsi que leurs interprétations.

La problématique de ce mémoire est de proposer des méthodes de segmentation basées sur la métaheuristiques d'optimisation afin d'améliorer la qualité de segmentation. La méthode de segmentation par classification 'K-Means' a été évoquée dans le but d'être comparée avec ces dernières.

CHAPITRE 2

METAHEURISTIQUES D'OPTIMISATION

CHAPITRE 2

METAHEURISTIQUES D'OPTIMISATION

2.1 INTRODUCTION

Dans la plupart des cas, les problèmes technologiques, comme le traitement d'images, peuvent être exprimés sous la forme générale d'un problème d'optimisation, dans lequel on définit une fonction objectif (voir plusieurs), que l'on cherche à minimiser ou à maximiser. Cette fonction est souvent soumise à des contraintes. Une solution ou plusieurs sont retenues, si à la fois, leurs paramètres satisfont ces contraintes et optimisent la fonction objectif [21].

Dans ce chapitre, nous exposerons les différents problèmes d'optimisation ainsi que les métaheuristiques comme méthodes approchées pour la résolution des problèmes dits NP-difficile.

2.2 PROBLEMES D'OPTIMISATION

Selon le nombre d'objectifs à optimiser, on distingue deux sortes d'optimisation: optimisation monoobjectif et multiobjectif.

2.2.1 OPTIMISATION MONO OBJECTIF

Comme son nom l'indique, le nombre d'objectifs à optimiser étant un seul. Le but fixé est de trouver une solution \vec{x} qui donne la meilleure qualité d'une fonction objectif $f(\vec{x})$ sous contraintes d'optimisation. Mathématiquement, le problème se présente comme suit :

Minimiser (maximiser) $f(\vec{x})$	(fonction à optimiser)
avec $\vec{g}(\vec{x}) \leq 0$	(m contraintes d'inégalité de type \leq)
et $\vec{h}(\vec{x}) \geq 0$	(p contraintes d'inégalité de type \geq)
et $\vec{l}(\vec{x}) = 0$	(q contraintes d'égalité)

où $f(\vec{x}) \in R$, $\vec{x} \in R^n$, $\vec{g} \in R^m$, $\vec{h} \in R^p$ et $\vec{l} \in R^q$.

2.2.2 OPTIMISATION MULTIOBJECTIF

Appelé aussi optimisation multicritère. Elle est née du besoin de l'industrie à satisfaire plusieurs critères contradictoires. Les bases de cette dernière ont été proposées par Pareto [22]. Mathématiquement, Le problème est formulé comme suit :

Minimiser (maximiser) $f(\vec{x})$ (fonction à optimiser)
 avec $\vec{g}(\vec{x}) \leq 0$ (m contraintes d'inégalité de type \leq)
 et $\vec{h}(\vec{x}) \geq 0$ (p contraintes d'inégalité de type \geq)
 et $\vec{l}(\vec{x}) = 0$ (q contraintes d'égalité)
 où $f(\vec{x}) \in R^k$, $\vec{x} \in R^n$, $\vec{g} \in R^m$, $\vec{h} \in R^p$ et $\vec{l} \in R^q$.

Dans ce type d'optimisation, on cherche à satisfaire plusieurs objectifs à la fois. Le concept d'optimum est différent de celui du monoobjectif. En effet, on est plus ici à la recherche d'un optimum global unique, mais plutôt, d'une surface de solutions qui offrent un bon compromis entre ces différents objectifs. Avant d'exposer les différentes approches de résolution des problèmes multiobjectifs, nous introduisons la relation de **dominance** [21] qui est définie par :

Soient deux vecteurs \vec{x}_1 et \vec{x}_2 . On dit que le vecteur \vec{x}_1 domine le vecteur \vec{x}_2 si :

- \vec{x}_1 est au moins aussi bon que \vec{x}_2 dans tous les objectifs ;
- \vec{x}_1 est strictement meilleur que \vec{x}_2 dans au moins un objectif.

Lors de la résolution d'un problème multiobjectif, on obtient souvent une multitude de solutions, mais juste un nombre restreint de ces solutions sera retenu (juste les solutions optimales). Les solutions qui dominent les autres mais ne se dominent pas entre elles sont appelées **solutions optimales au sens de Pareto** (ou bien, **solutions non dominées**, ou encore, **front de Pareto**). L'exemple de la figure 2.1 illustre bien cette relation de dominance, où f_1 et f_2 sont deux fonctions objectifs à minimiser.

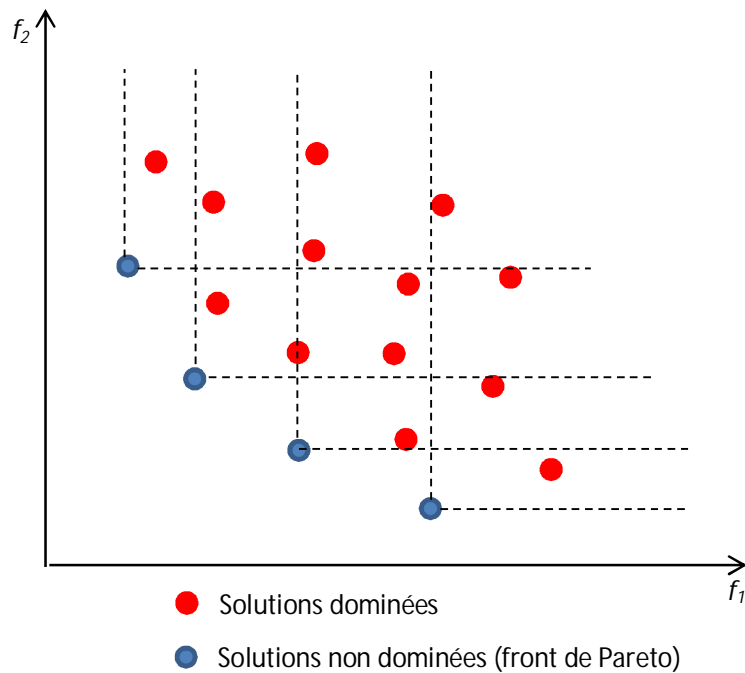


Figure 2.1 : Optimalité au sens de Pareto

2.2.3 DIFFÉRENTES APPROCHES DE RESOLUTION DE PROBLEME MULTIOBJECTIF

2.2.3.1 APPROCHE AGREGATIVE

Cette approche est qualifiée de naïve, elle consiste à transformer un problème multiobjectif en un problème monoobjectif en combinant linéairement les différents critères f_i en un unique critère F .

$$F(\vec{x}) = \sum_{i=1}^k a_i f_i(\vec{x}) \quad (2.1)$$

Où les paramètres a_i sont strictement positifs. Ils désignent les poids affectés à chaque critère f_i , $\sum_{i=1}^k a_i = 1$, k étant le nombre de critères.

L'avantage de ces méthodes est leur simplicité de mise en œuvre au sens où elles ne produisent qu'une seule solution, ce qui ne nécessite pas l'intervention d'un opérateur extérieur. Toutefois, pour atteindre cet objectif, deux problèmes doivent être résolus :

La détermination des paramètres a_i associés à chaque critère, et le choix de l'interaction entre ces différents critères [23] [24].

Concernant le premier problème, des stratégies aveugles sont présentes dans la littérature [25]. Elles consistent à résoudre le problème avec différentes valeurs des a_i puis opter pour les meilleures valeurs.

Ces méthodes atteignent leurs limites lorsque le problème possède une frontière de Pareto non convexe [25]. Dans l'exemple de la figure 2.2 où l'on minimise deux objectifs f_1 et f_2 , on voit que les solutions x et y peuvent être trouvées mais pas celles entre ces dernières.




Figure 2.2 : Front de Pareto non convexe. A est le domaine réalisable

2.2.3.2 APPROCHE NON AGREGATIVE

Appelée aussi approche non Pareto. Les méthodes basées sur cette approche traitent les objectifs séparément. La sélection des solutions candidates pour l'optimisation se fait de deux manières : par ordre défini à priori (sélection lexicographique) ou en parallèle.

Dans l'approche par sélection lexicographique, c'est l'ordre qui définit les poids des objectifs [26]. Dans celle par sélection parallèle, les solutions courantes du front de Pareto

sont sélectionnées suivant chaque objectif indépendamment des autres. Le premier travail suivant cette démarche qui a été publié était VEGA ('vector evaluated genetic algorithm') [27]. Des études analytiques sur les algorithmes basés sur cette approche ont montré qu'ils se comportent comme ceux basés sur l'approche agrégative [28].

2.2.3.3 APPROCHE PARETO

Contrairement aux autres approches qui combinent les critères ou les traitent séparément, celle-ci utilise la notion de dominance pour la sélection des solutions candidates qui feront converger la population vers un ensemble de solutions meilleures (front de Pareto). En effet, elle traite les objectifs équitablement, sans avoir à les comparer à priori [21] [26]. Le choix de solution finale revient à l'utilisateur.

2.3 OPTIMISATION DIFFICILE

Les problèmes d'optimisation difficile représentent une classe de problèmes pour lesquels les méthodes directes ou déterministes n'arrivent pas à trouver une solution satisfaisante. Ils sont regroupés en deux catégories : les problèmes combinatoires (ou problème discrets), et les problèmes à variables continues. Le premier cas rassemble les problèmes de type NP-complet, tel que le problème du voyageur du commerce que l'on peut facilement décrire à l'aide d'un algorithme polynomial sous la forme d'un sous ensemble de distance mais dont le nombre de combinaisons possibles pour sa résolution croît de manière exponentielle avec la taille de l'instance.

Dans le deuxième cas, les variables d'optimisation sont continues. On peut citer par exemple celui de rechercher des valeurs à affecter à un modèle numérique pour qu'il reproduise au mieux le comportement observé.

Selon Collette [21], un problème d'optimisation est qualifié de difficile si :

- On ne connaît pas d'algorithme exact rapide pour le résoudre. C'est le cas, en particulier de problèmes dits « NP-difficile », où l'on ne peut pas résoudre exactement dans un temps de calcul proportionnel à N^n , où N désigne le nombre de paramètres inconnus, et n est un entier (cas de problèmes combinatoires).
- On ne connaît pas d'algorithme permettant de repérer un optimum global à coup sûr et en un nombre fini de calculs (cas problèmes à variables continues).

2.4 LES METAHEURISTIQUES

Pendant longtemps, la recherche s'est orientée vers la proposition d'algorithmes exacts pour la résolution des problèmes d'optimisation. Mais avec l'augmentation de la complexité de ces derniers et l'explosion combinatoire des possibilités, il est devenu très difficile, voir, impossible de trouver une solution exacte. Une nouvelle classe d'heuristique, nommé « métaheuristiques », est apparue dans le but de mieux résoudre ces problèmes d'optimisation difficile. En effet, les métaheuristiques peuvent s'extraire des minimums locaux des fonctions objectifs en tolérant des dégradations temporaires (de C_n^* vers C_n' , voir l'exemple de la figure 2.3) contrairement aux algorithmes itératifs classiques comme ceux basés sur le gradient (piégés dans C_n^* , figure 2.3) [29]. Elles s'appliquent à toutes sortes de problèmes combinatoires, et elles peuvent également s'adapter aux problèmes continus. Les métaheuristiques les plus populaires peuvent être trouvées dans [29] et [21].

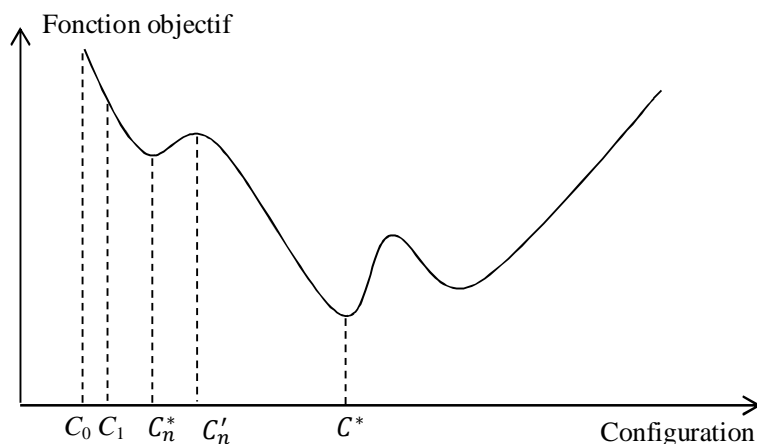


Figure 2.3 : Allure d'une fonction objectif d'un problème d'optimisation difficile

2.4.1 LE RECUIT SIMULE

Le recuit simulé est une métaheuristique à voisinage, présentée pour la première fois par Kirkpatrick [30] au début des années 80. Elle s'inspire de la technique expérimentale de la métallurgie pour obtenir un état solide bien stable d'un métal (un état d'énergie minimale). Le principe du recuit consiste à porter un métal à une température très élevée, puis à abaisser lentement celle-ci. En Algorithmique d'optimisation, ce principe a été fidèlement reproduit. Ainsi, la température, paramètre essentiel du recuit physique, est directement utilisée dans la

méthode du recuit simulé comme paramètre de contrôle. De même, par analogie avec le processus physique, l'énergie du système devient la fonction de coût à minimiser. Pour simuler l'évolution thermodynamique du système, le recuit simulé utilise l'algorithme de Metropolis [31] pour l'acceptation ou le rejet d'une solution candidate. Ce dernier s'appuie sur la distribution de Boltzmann utilisée en physique pour déterminer la distribution des particules en fonction de leur niveau d'énergie.

2.4.1.1 ALGORITHME DE METROPOLIS

L'algorithme de Metropolis est un algorithme itératif qui permet à un système simulé d'atteindre l'équilibre thermodynamique à une température T . son principe consiste en deux itérations :

- évaluer la variation d'énergie associée à une transition élémentaire aléatoire de l'état courant i , d'énergie E_i , vers un nouvel état j , d'énergie E_j :

$$\Delta E_{ij} = E_j - E_i \quad (2.2)$$

- accepter la transition vers le nouvel état avec une probabilité P_{ij}

où

$$\begin{cases} P_{ij}(T) = 1 & \text{si } \Delta E_{ij} \leq 0 \\ P_{ij}(T) = \exp\left(-\frac{\Delta E_{ij}}{T}\right) & \text{si } \Delta E_{ij} > 0 \end{cases} \quad (2.3)$$

La finalité de cet algorithme est de permettre une dégradation temporaire de la fonction objectif afin de s'extraire des minima locaux.

2.4.1.2 ALGORITHME DU RECUIT SIMULE

Le principe du recuit simulé est présenter dans l'algorithme 2.1, à partir d'une température initiale élevée T_i , et d'une solution initiale x_i d'une énergie E_i , on génère une nouvelle solution voisine. Si cette nouvelle solution améliore la fonction objectif ($\Delta E_{ij} \leq 0$), elle est acceptée et considérée temporairement comme solution optimale. Sinon, elle sera acceptée quand même avec une probabilité $P_{ij}(T) = \exp\left(-\frac{\Delta E_{ij}}{T}\right)$. Pratiquement, ceci se fait en générant un nombre aléatoire entre 0 et 1; si ce nombre est supérieur à $\exp\left(-\frac{\Delta E_{ij}}{T}\right)$, elle sera acceptée sinon, rejetée. Le procédé est itéré jusqu'à l'équilibre thermodynamique en gardant la température constante. Puis, on abaisse la température lentement en suivant un mécanisme de décroissance par paliers qui est souvent empirique [26].

```

Définir la fonction objectif  $f$ 
Choisir un mécanisme de perturbation d'une configuration courante.
Tirer une configuration aléatoire  $S_i$ .
Calculer l'énergie  $E$  associée à cette configuration.
Initialiser la température ( $T_0$ ).
Tant que Conditions d'arrêts pas satisfaites faire
    Tant que l'équilibre thermodynamique pas atteint faire
        Tirer une nouvelle configuration  $S_j$ .
        Appliquer la règle de Metropolis.
        Si  $P_{ij}(T) = 1$ 
             $f_{min} = f(S_j)$ 
             $S_i = S_j$ 
        Sinon
            Générer un rand  $R \in [0, 1]$ 
            Si  $R > P_{ij}(T)$ 
                 $f_{min} = f(S_j)$ 
                 $S_i = S_j$ 
            Fin de si
        Fin de tant que
    Fin tant que
Décroître la température.
Fin tant que
Afficher  $S_i$ 

```

Algorithme 2.1 : Algorithme du recuit simulé

2.4.2 ALGORITHMES DE COLONIES DE FOURMIS

L'algorithme d'Optimisation par Colonies de Fourmis prend son origine dans les travaux de Dorigo [32] au début des années quatre-vingt-dix, qui ont proposé un algorithme nommée « *Ant System* » pour la résolution du problème du voyageur du commerce. Ces algorithmes sont basés sur des études du comportement collectif des fourmis dans la recherche de nourriture. Les fourmis communiquent entre elles par l'intermédiaire de la phéromone, une substance qu'elles déposent sur le sol en se déplaçant et qui est détectée par les autres fourmis. Si une source importante de nourriture est située près du nid, les premières fourmis qui la trouvent feront le trajet de cette source au nid plusieurs fois. Elles y déposeront une quantité croissante de phéromone qui attirera davantage de fourmis. Ce trajet deviendra donc, après un certain temps, privilégié par les fourmis. Une fois la source de nourriture

épuisée, les fourmis arrêteront de l'emprunter, la phéromone s'évaporerait et d'autres trajets seraient définis. S'il arrivait qu'un obstacle, par exemple une pierre ou une branche d'arbre, vienne bloquer le trajet emprunté par les fourmis, ces dernières essaieront alors de le contourner à gauche et à droite de façon à peu près aléatoire jusqu'à ce qu'elles aient retrouvé la trace de la phéromone. Les fourmis ayant choisi la route la plus courte effectuant un plus grand nombre d'allers-retours, la quantité de phéromone déposée y sera plus importante et cette route deviendra éventuellement empruntée par toutes les fourmis (figure 2.3).

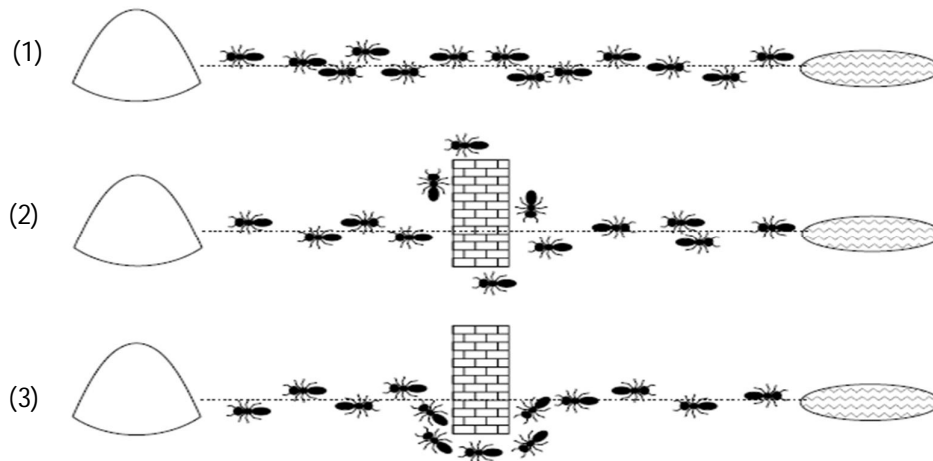


Figure 2.3 : Faculté d'une colonie de fourmis de retrouver le chemin le plus court

1. Des fourmis réelles suivent un chemin entre le nid et la source de nourriture
2. Un obstacle survient sur le chemin, les fourmis choisissent de tourner à droite ou à gauche, avec des probabilités égales ; les phéromones seront plus vite déposées sur le chemin le plus court.
3. Toutes les fourmis ont choisi le chemin le plus court.

L'adaptation du comportement et des caractéristiques des fourmis réelles pour l'optimisation a nécessité quelques modifications, d'où la naissance des fourmis artificielles qui possèdent une mémoire et qui ne sont jamais aveugles, ajoutant à cela, la discrétisation du temps [33]. L'algorithme 2.2 illustre l'algorithme de base 'Ant System' appliqué au problème du voyageur du commerce qui consiste à trouver le trajet le plus court reliant n villes données, chaque ville ne doit être visitée qu'une seule fois. Le problème est généralement défini comme un graphe complètement connecté.

La modélisation des fourmis artificielles pour la résolution de ce problème est la suivante: à chaque itération t , chaque fourmi k parcourt le graphe et construit un trajet complet de n étapes. Pour chaque fourmi, le trajet entre une ville i et une ville j dépend de :

- 1- La **liste des villes déjà visitées** qui définit les mouvements possibles à chaque pas, quand la fourmi k est sur la ville $i : J_i^k$;
- 2- La **visibilité** de chaque fourmi est définie par l'inverse de la distance entre les villes : $v_{ij} = \frac{1}{d_{ij}}$. Ce qui permet aux fourmis de se déplacer vers les villes les plus proches.
- 3- L'**intensité de la piste** $\tau_{ij}(t)$ correspond à la quantité de phéromone déposée sur le chemin reliant deux villes. Ce qui définit une pseudo-mémoire globale du système.

L'heuristique du déplacement, appelée la probabilité de transition [34] est définie par :

$$p_{ij}^k(t) = \begin{cases} \frac{(\tau_{ij}(t))^\alpha (v_{ij})^\beta}{\sum_{l \in J_i^k} (\tau_{il}(t))^\alpha (v_{il})^\beta} & \text{si } j \in J_i^k \\ 0 & \text{sinon} \end{cases} \quad (2.4)$$

Où α et β sont contrôlant l'importance relative à l'intensité et à la visibilité.

Après un tour complet, chaque fourmi dépose une quantité de phéromone $\Delta\tau_{ij}^k(t)$ sur l'ensemble de son parcours. Cette quantité dépend de la qualité de la solution trouvée et est définie par :

$$\Delta\tau_{ij}^k(t) = \begin{cases} \frac{Q}{L^k(t)} & \text{si } (i, j) \in T^k(t) \\ 0 & \text{sinon} \end{cases} \quad (2.5)$$

Où $T^k(t)$ est le trajet effectué par la fourmi k à l'itération t , $L^k(t)$ est la longueur de $T^k(t)$ et Q est un paramètre fixé.

Enfin, il est nécessaire d'introduire un processus d'évaporation des phéromones. En effet, pour éviter le piégeage dans des solutions sous optimales, c'est important que le système oublie les mauvaises solutions. La règle des mises à jour des pistes est :

$$\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (2.6)$$

Où $\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t)$ et m est le nombre de fourmis.

Tant que le critère d'arrêt n'est pas atteint **faire**
 Pour $k=1$ à m **faire**
 Choisir une ville au hasard
 Pour chaque ville non visitée i **faire**
 Choisir une ville j , dans la liste J_i^k des villes restantes selon (2.4)
 Fin Pour
 Déposer une piste $\Delta\tau_{ij}^k(t)$ sur le trajet $T^k(t)$ conformément à (2.5)
 Fin Pour
 Évaporer les pistes selon (2.6)
Fin Tant que

Algorithme 2.2 : Algorithme de colonies de fourmis de base : Ant System

2.4.3 ALGORITHMES GENIQUES

Les premiers travaux sur les algorithmes génétiques sont apparus au début des années soixante [35]. Ce sont des algorithmes d'optimisation à population s'appuyant sur des techniques dérivées de la génétique et de la sélection naturelle.

La théorie de la sélection naturelle s'applique aux individus d'une population et repose sur trois principes [36] :

- **la variation** : les individus diffèrent les uns des autres ;
- **l'adaptation** : les individus les mieux adaptés à leur environnement vivent plus longtemps et procréent plus ;
- **l'hérédité** : les caractéristiques des individus sont héréditaires.

Dans de tels algorithmes, les populations sont évaluées de manière itérative suivant les grandes étapes suivantes :

1. création d'une population initiale. De cette population dériveront toutes les futures Générations. Il est donc préférable qu'elle couvre une large partie de l'espace des solutions du problème ; c'est pourquoi elle est souvent créée de manière aléatoire ;
2. une boucle itérative permet de faire évoluer la population en générations successives avec l'aide de trois principes :
 - **l'adaptation** d'un individu qui correspond à la valeur relative de la fonction objectif entre cet individu et les autres ;

- la **sélection** des individus de la population en deux étapes. Premièrement, la sélection des futurs parents (c'est-à-dire ceux qui vont se reproduire) par l'opérateur de sélection. Cela ne veut pas dire que les autres membres de la population vont disparaître, car cette disparition est l'objet de la seconde sélection. Deuxièmes, la sélection de la population qui sera présente à la prochaine itération. Cette sélection est assurée par l'opérateur de remplacement;
 - la **diversification** de la population. C'est ce qui va permettre d'explorer l'espace des solutions. Les parents sélectionnés ont deux possibilités pour engendrer des enfants : le croisement et la mutation. Les individus créés seront les enfants de cette itération.
3. un critère d'arrêt qui met fin à la recherche. Il peut être fonction du nombre de générations, de l'adaptation du meilleur individu ou encore du temps passé.

Le pseudo code d'un algorithme génétique est donné dans l'algorithme 2.3.

```
Initialisation de la population
Evaluation des fonctions objectifs de chaque individu
Calculer l'efficacité de chaque individu
Tant que le critère d'arrêt n'est pas atteint faire
    Sélection de parent pour la reproduction
    Mutation
    Croisement
    Evaluation des fonctions objectifs de chaque enfant
    Calculer l'efficacité de chaque enfant
    Sélection pour remplacement
Fin Tant que
```

Algorithme 2.3 : Pseudo code d'un algorithme génétique

2.4.3.1 OPERATEUR DE SELECTION POUR REPRODUCTION

Généralement, La sélection d'un individu pour la reproduction dépend de sa performance. L'opérateur de sélection est ainsi chargé de déterminer un nombre de sélections pour chaque individu. Il existe plusieurs opérateurs de sélections :

- **Sélection par tournoi** : une loi de probabilité uniforme est utilisée pour sélectionner des couples d'individus dans la population. Dans chaque couple sélectionné, les deux individus combattent l'un contre l'autre. Lors de chaque combat, l'individu le mieux adapté l'emporte avec une probabilité comprise dans l'intervalle] 0.5, 1], qui est un paramètre de la méthode permettant le réglage de la pression sélective. Dans ce type de sélection, un super individu sera sélectionné plusieurs fois et prendra la place de plusieurs parents ;
- **sélection par roulette** : c'est une méthode proportionnelle. Son nom vient de l'analogie avec le tirage aléatoire des roulettes de casino. A chaque individu i est associée une probabilité d'être choisi proportionnelle à son adaptation : $P_i = f_i / \sum_j f_j$. Puis plusieurs tirages aléatoires dans l'intervalle [0; 1] sont effectués permettant, ainsi, de sélectionner les futurs parents. La variance de ce processus est élevée. Dans le pire cas, il est possible qu'aucun individu bien adapté ne soit pas sélectionné. Ce phénomène, appelé biais de sélection, peut être limité avec une population nombreuse (figure 2.4).




Figure 2.4 : Roue servant à sélectionner un individu pour reproduction. L'individu (2) a plus de chance d'être sélectionné

- **sélections par échantillonnage stochastique universel** (Stochastic Universal Simpling,SUS) [37] : qui est une variante de la roulette, mais celle-ci se fait juste avec un seul tirage d'un offset aléatoire. Les parents sélectionnés sont ceux pointés par le pointeur équidistant (figure 2.5).




Figure 2.5 : Méthode SUS, les individus sélectionnés sont désignés par les pointeurs équidistants

2.4.3.2 OPERATEURS DE DIVERSIFICATION

La diversification permet à l'algorithme génétique d'explorer l'espace des solutions à la recherche d'un optimum global (ou plusieurs). Cette étape consiste à créer de nouvelles solutions (des enfants) à partir des solutions sélectionnées pour la reproduction (les parents). Les algorithmes évolutionnaires se sont inspirés des méthodes de reproduction du vivant pour créer des opérateurs de diversification. Le croisement joue le rôle de la reproduction sexuée et la mutation celui de la reproduction asexuée :

- le **croisement** nécessite plusieurs parents, en général deux, pour produire un ou plusieurs enfants. Cet opérateur combine les gènes (éléments caractérisant une solution) des parents pour créer les enfants. L'idée sous-jacente est qu'il va être possible de remplacer quelques gènes « pauvres » d'un parent par les gènes correspondants plus « riches » d'un autre parent. Cet opérateur n'est donc pas nécessairement aléatoire. Une illustration d'un opérateur standard de croisement est présentée figure 2.6.a ;
- la **mutation** consiste à modifier localement un ou plusieurs éléments de la population. C'est un opérateur très simple mais essentiel au fonctionnement des algorithmes évolutionnaires, car il assure la diversification de la population. Une façon simple de créer une mutation est de modifier aléatoirement un ou plusieurs gènes d'un individu en respectant les contraintes du problème. Une illustration d'un opérateur standard de mutation est présentée dans la figure 2.6.b.

L'opérateur de mutation est souvent plus utilisé pour explorer l'espace des solutions et l'opérateur de croisement pour atteindre les optima locaux. Ainsi, lorsque la mutation est suffisamment aléatoire, les croisements peuvent être plus déterministes. Les opérateurs de croisement et de mutation sont délicats à régler. Trop simple et/ou pas assez nombreuse la

mutation va s'enfermer dans un optimum local ; trop compliquée et/ou trop nombreuse elle va empêcher la convergence de l'algorithme [36].

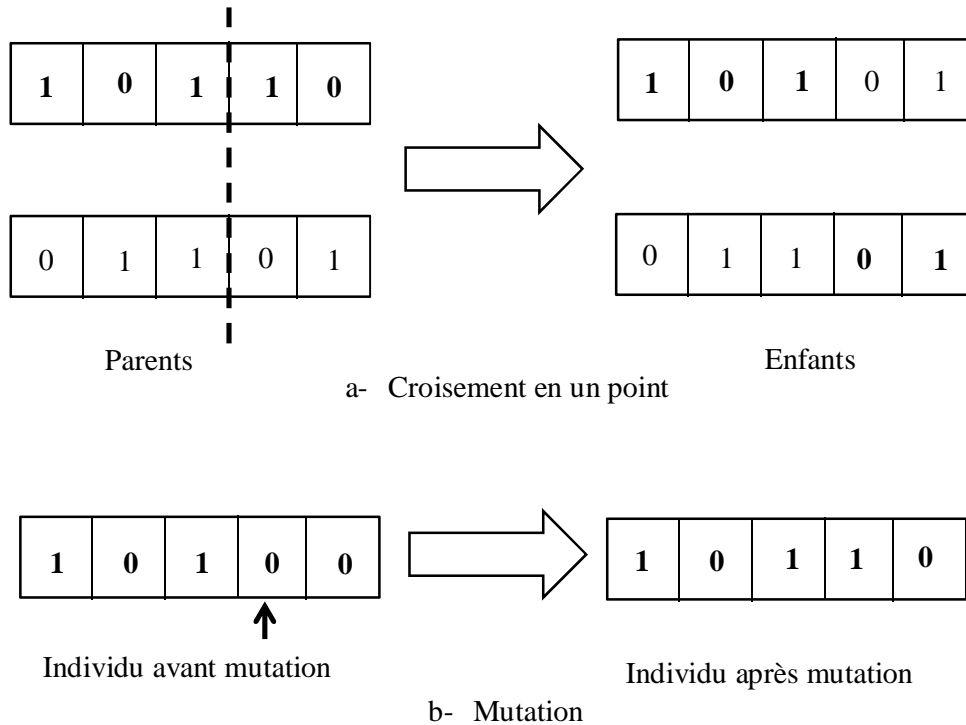


Figure 2.6 : Exemples d'opérations de diversification

2.4.3.3 OPERATEURS DE REMPLACEMENT

L'opérateur de remplacement a pour rôle d'assurer la prolifération des meilleurs individus au détriment des plus mauvais. Au cours de cette étape, la probabilité de survie de chaque individu doit donc correspondre à son adaptation. Plusieurs opérateurs de remplacement existent :

- le **remplacement par génération** consiste à ne conserver que les enfants dans la génération suivante ;
- le **remplacement des stratégies d'évolution** est une sélection déterministe qui permet de sélectionner les meilleurs individus parmi l'ensemble des parents et des enfants ;
- l'**élitisme** consiste à conserver au moins un individu possédant la meilleure adaptation. Cet opérateur est couplé avec un autre opérateur qui sélectionne le reste de la

population. L'élitisme peut améliorer considérablement les performances d'un algorithme évolutionnaire pour certaines classes de fonctions, mais s'avèrent décevant pour d'autres classes, en augmentant le taux des convergences prématurées [38].

Il faut distinguer l'opérateur de sélection de celui de remplacement. L'opérateur de sélection est chargé de sélectionner les parents parmi la population, alors que l'opérateur de remplacement détermine la nouvelle population à partir des enfants et des parents.

2.5 METAHEURISTIQUES EN SEGMENTATION D'IMAGES

Nous exposerons dans cette partie quelques travaux portant sur l'application des métaheuristiques aux problèmes de segmentation d'images.

Le recuit simulé

Le recuit simulé a été appliqué pour la segmentation d'images par seuillage. Le but était de trouver une meilleure approximation des histogrammes par des combinaisons de gaussienne dont les paramètres sont à déterminer. La justification de l'utilisation du recuit c'est que le problème d'approximation de l'histogramme est un problème d'optimisation non linéaire qui présente de nombreux minima locaux [23] [39] ;

Dans [40], le recuit simulé a été appliqué pour la segmentation multicritère des images de télédétections en se basant sur la technique *AMOS* (*archived multiobjective simulated annealing technique*) [41] pour une classification floue optimale des pixels en faisant intervenir en parallèle deux objectifs, indices d'une bonne classification. Le résultat final est un ensemble de solutions non dominées dont le choix d'une solution unique revient à l'utilisateur, selon le domaine d'application.

Une autre approche multiobjectif de segmentation était proposée par [42], celle-ci combine l'entropie à deux dimensions et la méthode d'Otsu à deux dimensions [43] qui tient en compte même l'information spatiale de l'image. Ainsi, le résultat de segmentation obtenu était très satisfaisant.

Les colonies de fourmis

Zhao [44] a proposé un algorithme de colonies de fourmis qui consiste à générer des seuils initiaux et à attribuer chaque pixel au seuil le plus proche. Puis, à faire circuler des

fourmis artificielles entre l'ensemble des points et des seuils. Les pixels sont regroupés selon l'accumulation des phéromones qui sont ajustés à chaque itération de l'algorithme.

Une approche de segmentation basée sur le clustering a été proposée par Ghosh [45], cette approche est appelée « approche par agrégation de phéromone ». Dans celle-ci, une fourmi artificielle est placée en chaque point (pixel). Les fourmis se déplacent dans l'espace de recherche à la recherche des régions homogènes et suivant l'importance de la densité de phéromone. Une approche agglomérates est appliquée à la fin pour rassembler les régions similaires, car le nombre de segments formés à la fin dépasse souvent le nombre désiré.

Les algorithmes génétiques

Dans [46], l'auteur a proposé un algorithme de segmentation d'image par approche région. Il a utilisé les algorithmes génétiques pour maximiser la qualité des partitions homogènes (régions) générées par une étape de division-fusion.

Un algorithme génétique multiobjectif a été proposé par Shirakawa [47] pour la segmentation multicritère d'images couleur par approche contours. Celui-ci utilise deux critères afin d'améliorer la qualité de segmentation : un critère sur le contour, un autre sur la distorsion totale des partitions. La population initiale est générée en utilisant la technique MST (Minimum Spanning Tree), les plus grandes arêtes sont, ensuite, supprimées pour avoir les partitions initiales. Les centres de celles-ci sont calculées à chaque génération afin d'apprécier la distorsion totale suivi d'une étape de réajustement des partitions selon les deux critères.

2.6 CONCLUSION

Dans ce chapitre, nous avons présenté un aperçu sur les métaheuristiques les plus populaires. Nous avons introduit les problèmes d'optimisation monoobjectif, multiobjectif et le concept d'optimisation difficile. Les différentes approches de résolution des problèmes multiobjectifs ont été exposées.

Les métaheuristique constituent une classe de méthodes approchées applicables sur un grand nombre de problèmes combinatoires et peuvent s'adapter aux problèmes continus. Dans le prochain chapitre les métaheuristiques seront utilisées pour améliorer la qualité de segmentation, dans un premier temps, en monoobjectif et finalement, en multiobjectif.

CHAPITRE 3

APPLICATION DES ALGORITHMES GENETIQUES POUR LA SEGMENTATION D'IMAGES

CHAPITRE 3

APPLICATION DES ALGORITHMES GENETIQUES POUR LA SEGMENTATION D'IMAGES

3.1 INTRODUCTION

Les images de télédétection sont caractérisées essentiellement par deux sortes d'attributs : attributs spectraux et texturaux [48] [49]. Pour ce fait, nous avons consacré une partie de ce chapitre à la méthode d'extraction d'attributs texturaux par matrices de cooccurrences, l'extraction des attributs spectraux sera exposée dans le prochain chapitre.

Après avoir reformulé le problème de segmentation d'image en un problème d'optimisation, nous allons présenter des algorithmes génétiques basés sur deux approches différentes (monoobjectif et multiobjectif) pour la segmentation d'images par classification selon ces attributs.

3.2 REFORMULATION DU PROBLEME DE SEGMENTATION D'IMAGES EN UN PROBLEME D'OPTIMISATION

Les méthodes de segmentation d'images par classification sont issues du domaine de la classification des données multidimensionnelles. Elles définissent 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.

Ce problème de classification constitue un problème NP-difficile [50] [51], donc, il ne peut pas être résolu exactement dans un temps de calcul raisonnable. Nous ajoutons à ce problème des fonctions qui indiquent une cohésion des classes que nous optimiserons avec les algorithmes génétiques ;

Les fonctions que nous avons ajoutées sont :

- 1- En monoobjectif : inertie intra-classes (erreur quadratique) $D_T(C)$, dont le minimum est un indice d'une bonne classification. elle est exprimée par la relation suivante :

$$D_T(C) = \sum_{i=1}^k \sum_{j=1}^{Q_i} d(x_j^{(i)}, \bar{x}_i)^2 \quad (3.1)$$

Où k es le nombre de classe ; Q_i , le nombre de pixels de la classe i ; d , la distance entre le pixel $x_j^{(i)}$ appartenant à la classe i et le centre de gravité \bar{x}_i de cette classe.

- 2- En multiobjectif :

- a- Variance intra-classes et la longueur du contour qui est à minimiser aussi, elle est définie par :

$$L(C) = \sum_{i=1}^{h-1} \sum_{j=1}^{l-1} \delta(P(i, j), p(i, j + 1)) + \delta(P(i, j), p(i + 1, j)) \quad (3.2)$$

$$\text{Avec } \delta(x, y) = \begin{cases} 1 & \text{si } x \neq y \\ 0 & \text{sinon} \end{cases} \quad (3.3)$$

h et l sont respectivement la hauteur et la largeur de l'image, $P(i, j)$ est la valeur du pixel de coordonnées (i, j) .

- b- variance intra-classes et la connectivité des pixels qui est à minimiser aussi, elle est définie par :

$$\text{conn}(C) = \sum_{i=1}^N \left(\sum_{j=1}^L x_{i, n_{ij}} \right) \quad (3.4)$$

$$\text{avec } x_{r,s} = \begin{cases} \frac{1}{j} & \text{si } \exists C_k, r \in C_k \text{ et } s \in C_k \\ 0 & \text{sinon} \end{cases} \quad (3.5)$$

n_{ij} est le $j^{\text{ème}}$ voisin du pixel i , N est le nombre de pixels, et L est le nombre de pixels voisins contribuant à la mesure de connectivité. Lorsque les pixels i et j ne sont pas dans la même classe, $x_{i, n_{ij}} = 1/j$ sinon 0.

3.3 APPLICATION DES ALGORITHMES GENETIQUES POUR LA SEGMENTATION D'IMAGES EN MONOOBJECTIF

Dans cette section, nous appliquons les algorithmes génétiques pour la segmentation d'images par l'approche de segmentation par classification. Le processus de segmentation est résumé par le schéma synoptique de la figure 3.1.

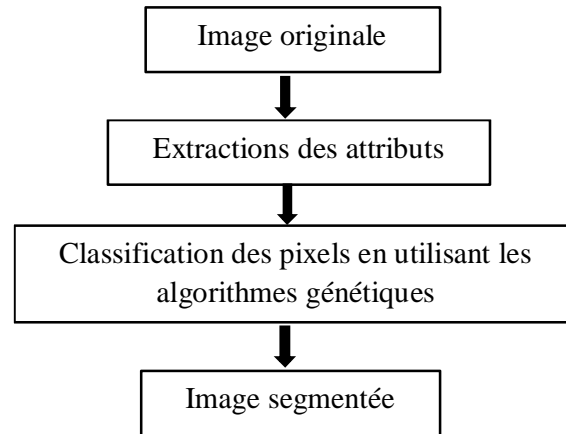


Figure 3.1 : Schéma synoptique du processus de segmentation

3.3.1 EXTRACTION D'ATTRIBUTS TEXTURAUX PAR MATRICES DE COOCCURRENCES

Pour prendre en compte l'information de voisinage dans une analyse de textures, il est intéressant d'utiliser des méthodes statistiques d'ordre deux du fait qu'elles mettent en jeu deux pixels simultanément. L'une des méthodes les plus utilisées est celle des matrices de cooccurrences ou méthode de dépendance spatiale des niveaux de gris appelée aussi SGLDM (Spatial Gray Level Dependence Method) introduite par *Haralick* [52]. Elle permet de déterminer la fréquence d'apparition d'un motif formé de deux pixels séparés par une distance dans plusieurs directions. Plusieurs travaux ont montré que les matrices de cooccurrences contiennent une information texturale importante qui améliore la discrimination des classes, plus particulièrement en télédétection [53] [54].

3.3.1.1 Principe

La matrice de cooccurrence est basée sur le calcul de la probabilité $P(i, j, \delta, \theta)$ qui représente le nombre de fois où un pixel de niveau de gris i apparaît à une distance relative δ d'un pixel de niveau de gris j et selon une orientation θ donnée (les directions angulaires θ les plus utilisées sont 0, 45, 90 et 135 degrés).

Les caractéristiques extraites à partir de ces matrices contiennent des informations notamment sur l'homogénéité, les dépendances linéaires entre les niveaux de gris, le contraste et la complexité de l'image en question. Les matrices obtenues selon ces quatre directions sont alors calculées comme dans (3.6), (3.7), (3.8) et (3.9) où (k, l) sont les coordonnées d'un pixel de niveau de gris $i \in [0, n^{\max} - 1]$ et (m, n) celles du pixel de niveau gris

$$j \in [0, n^{\max} - 1]$$

$$P(i, j, \delta, 0) = \text{card} \left\{ \left((k, l), (m, n) \right) \in (L_y \cdot L_x) \cdot (L_y \cdot L_x) \setminus \left(\begin{array}{l} k - m = 0, |l - n| = d, \\ I(k, l) = i, I(m, n) = j \end{array} \right) \right\} \quad (3.6)$$

$$P(i, j, \delta, 45) = \text{card} \left\{ \left((k, l), (m, n) \right) \in (L_y \cdot L_x) \cdot (L_y \cdot L_x) \setminus \left(\begin{array}{l} (k - m = d, l - n = -d) \text{ ou } \\ (k - m = -d, l - n = d), I(k, l) = i, I(m, n) = j \end{array} \right) \right\} \quad (3.7)$$

$$P(i, j, \delta, 90) = \text{card} \left\{ \left((k, l), (m, n) \right) \in (L_y \cdot L_x) \cdot (L_y \cdot L_x) \setminus \left(\begin{array}{l} |k - m| = d, k - m = 0, \\ I(k, l) = i, I(m, n) = j \end{array} \right) \right\} \quad (3.8)$$

$$P(i, j, \delta, 135) = \text{card} \left\{ \left((k, l), (m, n) \right) \in (L_y \cdot L_x) \cdot (L_y \cdot L_x) \setminus \left(\begin{array}{l} (k - m = d, l - n = d) \text{ ou } \\ (k - m = -d, l - n = -d), I(k, l) = i, I(m, n) = j \end{array} \right) \right\} \quad (3.9)$$

3.3.1.2 LES ATTRIBUTS TEXTURAUX

Quatorze paramètres descriptifs des textures, tels qu'ils sont définis par *Harralick* [52] peuvent être extraits à partir de la matrice de cooccurrence. Parmi ceux-ci, nous avons retenu les plus fréquemment utilisés en télédétection [55] [56] : l'énergie, l'entropie, contraste, corrélation, directivité, homogénéité locale et uniformité.

- **Energie**

$$Eng = \sum_i \sum_j P_{ij}(\delta, \theta)^2 \quad (3.10)$$

Ce paramètre mesure l'uniformité de la texture. Il atteint de fortes valeurs lorsque la distribution des niveaux de gris est constante ou de forme périodique. Dans ce dernier cas, les valeurs élevées d'énergie sont obtenues pour les matrices $P_{ij}(\delta, \theta)$ (lorsque (δ, θ) correspond à la période.

- **Entropie**

$$Ent = - \sum_i \sum_j P_{ij}(\delta, \theta) \log(P_{ij}(\delta, \theta)) \quad (3.11)$$

Ce paramètre mesure le désordre dans l'image. Contrairement à l'énergie, l'entropie atteint de fortes valeurs lorsque la texture est complètement aléatoire (sans structure apparente).

- **Contraste**

$$Cont = \sum_i \sum_j (i - j)^2 P_{ij}(\delta, \theta) \quad (3.12)$$

Le contraste permet de mesurer les variations locales des niveaux de gris. Une petite valeur de contraste indique une forte concentration des occurrences de niveaux de gris sur la diagonale principale de la matrice de cooccurrence et représente donc une texture grossière. Tandis qu'une grande valeur de contraste décrit des occurrences étalées autour de la diagonale principale et représente une texture fine. Si une image présente une faible dynamique, les valeurs de contraste sont très faibles et ne permettent pas alors de discriminer des sous-structures particulières.

- **Corrélation**

$$Cor = \frac{\sum_i \sum_j (i - \mu)(j - \mu) P_{ij}(\delta, \theta)}{\sigma^2} \quad (3.13)$$

Où μ et σ^2 désignent respectivement la moyenne et la variance ;

Ce paramètre mesure la dépendance directionnelle des niveaux de gris, il atteint ses plus grandes valeurs lorsque θ est proche de l'orientation des lignes de la texture.

- **Directivité**

$$Dir = \sum_i P_{ii}(\delta, \theta) \quad (3.14)$$

Elle permet de sommer les éléments diagonaux de la matrice de cooccurrence. Elle donne une valeur qui est de plus en plus importante lorsque la texture possède une orientation privilégiée dans le sens de la translation.

- **Homogénéité locale ou moment de différence inverse**

$$MDI = \sum_i \sum_j \frac{P_{ii}(\delta, \theta)}{1 + (i + j)^2} \quad (3.15)$$

L'homogénéité donne une idée des similarités locales. Il reflète l'existence de plages uniformes de texture et affecte un poids de plus en plus faible au fur et à mesure qu'on s'éloigne de la diagonale principale. Plus la valeur de l'homogénéité est élevée, plus la texture est grossière.

- **Uniformité**

$$Uni = \sum_i P_{ii}(\delta, \theta)^2 \quad (3.16)$$

Cette valeur est d'autant plus élevée qu'un même niveau de gris apparaît dans la texture.

3.3.1.3 LA REQUANTIFICATION

Avant d'extraire les attributs de texture dans une image, une requantification est souvent appliquée pour diminuer le temps de calcul [52]. Le choix d'une méthode de requantification est très délicat, en effet, un mauvais choix entraîne la perte de la majorité de l'information de l'image.

Supposons que l'histogramme d'une image texturée se présente comme montré dans la figure 3.2.a et que l'on souhaite requantifier l'image en six niveaux de gris.

On voit bien qu'en choisissant un pas de requantification constant (figure 3.2.b), la majorité de l'information est perdue (obtention de 3 zones, seulement), vu que celle-ci est concentrée entre 0 et 80, et entre 200 et 255.

Par contre, avec un pas variable (figure 3.2.c) selon la concentration des niveaux de gris, un résultat meilleur est obtenu. Ce principe est appelé « quantification équiprobable ». Il consiste à calculer les fréquences cumulatives des niveaux de gris à partir de l'histogramme, puis, à diviser la somme finale sur le nombre de niveaux de quantification désiré pour obtenir

un pas de requantification équiprobable. Les seuils de quantification sont obtenus par projection des fréquences cumulatives correspondantes aux pas sur l'axe des niveaux de gris.

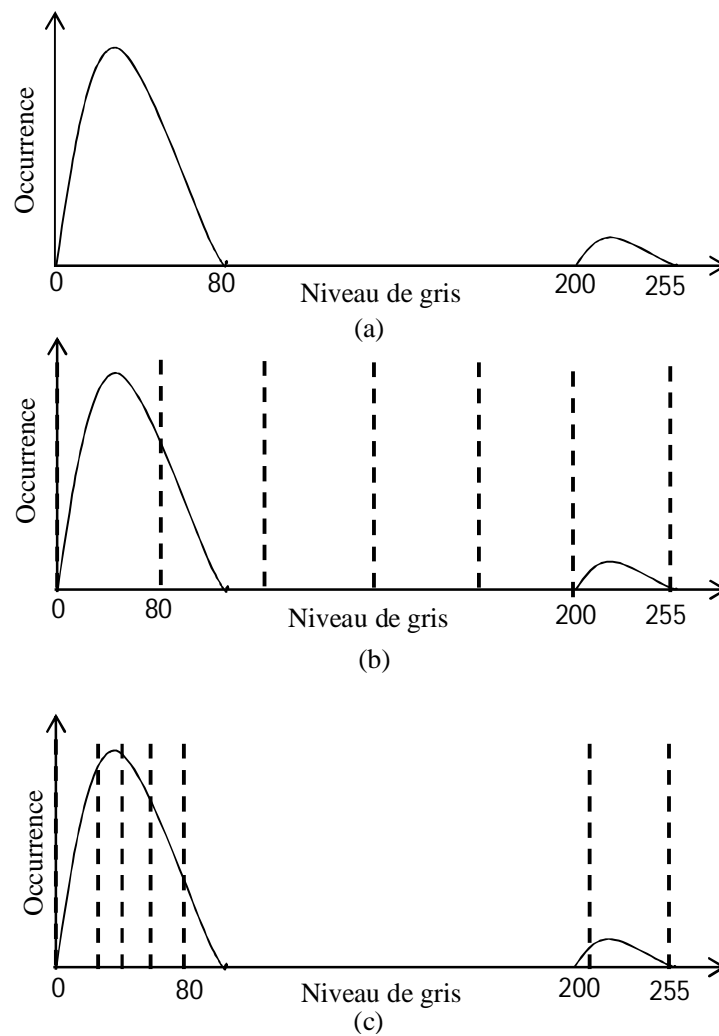


Figure 3.2 : Choix de seuils de requantification : a-histogramme de l'image ; b-mauvais choix, c-bon choix

3.3.2 CLASSIFICATION DES PIXELS

Après l'étape d'extraction des attributs, chaque pixel de l'image est caractérisé par un vecteur d'attributs de dimension égale au nombre d'attributs extraits. Pour classifier ces pixels, nous suivons la démarche expliquée dans le chapitre précédent, concernant les algorithmes génétiques.

3.3.2.1 POPULATION INITIALE

Pour mettre en œuvre l'algorithme génétique, une population initiale de N individus est générée. Chaque individu est représenté par un chromosome, chaque chromosome est constitué de K gènes qui correspondent à K centres de classes de D dimensions (figure 3.3).




Figure 3.3 : représentation génétique d'un individu

La génération des centres des classes se fait en deux étapes :

- 1- générer aléatoirement les centres des classes dans l'espace de recherche après avoir détecté les bornes inférieures et supérieures de chaque dimension, vu que les attributs ne sont pas de même ordre de grandeur.
- 2- mise à jour de ces centres par quelques itérations par l'algorithme des K-Means pour accélérer la convergence de l'algorithme génétique.

3.3.2.2 SELECTIONS POUR LA REPRODUCTION

Après la génération de la population initiale, chaque pixel est affecté à la classe dont le centre est plus proche. Tous les individus sont, alors, évalués selon la fonction illustrée par la formule (3.1) et des performances f_i leurs sont associées suivant la relation suivante :

$$f_i = \frac{1}{D_T(C)} \quad (3.17)$$

Pour chaque individu, on associe une probabilité de sélection proportionnelle à sa performance:

$$P_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (3.18)$$

Après le choix du taux de croisement, une sélection de E parents parmi les N individus par échantillonnage stochastique universel (Stochastic Universal Sampling, SUS) [37] est effectuée. Cette méthode de sélection permet même aux individus les moins performants

de se reproduire mais avec une faible probabilité de sélection. Les individus les plus performants peuvent être sélectionnés plusieurs fois, ce processus permet la multiplication des bons gènes dans la population (multiplication des solutions prometteuses).

3.3.2.3 CROISEMENT DES INDIVIDUS

Ce processus est essentiel pour remplacer les gènes pauvres des parents par des gènes plus performants.

Dans notre travail, nous avons choisi le croisement en deux points (un point si le gène se situe à l'une des extrémités du chromosome); deux parents, représentés par leurs chromosomes, s'échangent des gènes de même rang indexé par un entier généré aléatoirement.

3.3.2.4 MUTATION D'UN INDIVIDU

Expliquée dans le chapitre précédent, l'opération de croisement est nécessaire pour explorer tout l'espace de recherche.

Selon le choix de taux de mutation, un nombre M (correspondant au taux de mutation) d'individus seront mutés pour produire des individus nouveaux dont les caractéristiques sont différentes mais très proches des individus mutés. Pour se faire, un petit réel (relativement à la dimension considérée), généré aléatoirement dans chaque dimension, est soustrait ou ajouté à la valeur du centre correspondant.

3.3.2.5 SELECTIONS POUR LE REMPLACEMENT

Après l'étape de diversification (croisement et mutation), les enfants sont évalués de la même manière que sont évalués les individus dans l'opération de sélection pour la reproduction et des performances f_i leurs sont associées. Une population de $N+E$ individus est alors produite.

Les meilleurs N individus sont sélectionnés selon leurs fonctions d'adaptation f_i pour constituer une nouvelle génération de performance moyenne plus élevée.

3.3.2.6 CRITERE D'ARRET

Les processus d'optimisation par l'algorithme génétique proposé est itératif: La solution optimale est approchée de génération en génération. Après un nombre de génération

fixé au préalable le processus est arrêté. Une seule solution sera retenue : celle qui a le plus grande valeur de la fonction d'adaptation f_i dans la dernière génération.

3.3.2.7 SEGMENTATION

L'image segmentée est produite par la construction d'une image index de l'appartenance de pixels à chaque classe dont les centres sont représentés par l'individu retenu.

3.3 APPLICATION DES ALGORITHMES GENETIQUES POUR LA SEGMENTATION MULTICRITERE D'IMAGES

Dans cette section, durant le processus de classification des pixels, nous faisons intervenir en parallèle deux critères de segmentation : un indice de bonne classification (formule 3.1) et un autre indice complémentaire qui tient compte de l'information spatiale de l'image (formule 3.2 ou bien, formule 3.4)

Pour la suite, nous appellerons :

- Premier objectif : l'inertie intra-classes
- Deuxième objectif : longueur du contour ou bien la connectivité des pixels

L'extraction des attributs, la génération de la population initiale, la mutation, le croisement et le critère d'arrêt se font identiquement à ceux de la segmentation en monoobjectif. Nous n'exposerons que les étapes restantes.

3.3.1 SELECTIONS POUR LA REPRODUCTION

Après avoir classé les pixels, tous les individus sont évalués selon les deux objectifs.

Une représentation de ces derniers peut être faite dans un plan objectif-1, objectif-2. Un exemple de cette représentation, pris dans nos applications, est illustré dans la figure 3.4.

La sélection des individus se fait suivant ces quatre étapes :

- 1- Trier les individus selon leurs rangs de dominance (voir le chapitre précédent) : les individus du premier rang (surface de Pareto) dominant tous les individus restants, les individus du deuxième rang ne sont dominés que par ceux du premier, les individus du troisième rang sont dominés seulement par ceux du premier et du deuxième ..., jusqu'à ce que toute la population soit triée.

- 2- Attribuer à chaque individu une performance relative à son rang suivant la formule suivant :

$$f_i = \frac{1}{R_i} \quad (3.19)$$

Où R_i désigne le rang de l'individu i .

Ainsi la performance d'un individu est autant plus grande que son rang est plus petit.

- 3- Pour chaque individu, on associe une probabilité de sélection proportionnelle à sa performance selon la formule 3.18.
- 4- Application de l'échantillonnage stochastique universel pour la sélection de E parents parmi N pour la reproduction.

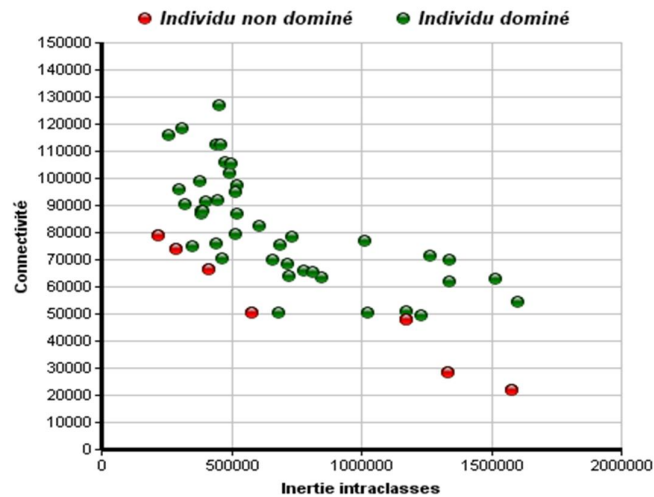


Figure 3.4: Représentation des individus dans un plan connectivité-inertie intraclasses

3.3.2 SELECTIONS POUR LE REMPLACEMENT

Les enfants produits après l'opération de diversification sont évalués selon les deux objectifs. L'ensemble des individus de la population (les N individus de départ et les E enfants produits) est trié selon les rangs de dominances correspondants. Une classification par ordre croissant selon le rang est, ensuite, effectuée. Les N premiers individus sont sélectionnés pour constituer la génération suivante.

3.3.3 SEGMENTATION

Lorsque le nombre maximum de générations est atteint, un ensemble de solutions non dominées est produit. Chaque solution constitue une solution de compromis entre les deux objectifs (figure 3.5). Des images segmentées, correspondant à ces solutions, sont obtenues par la construction des images index de l'appartenance de pixels à chaque classe.

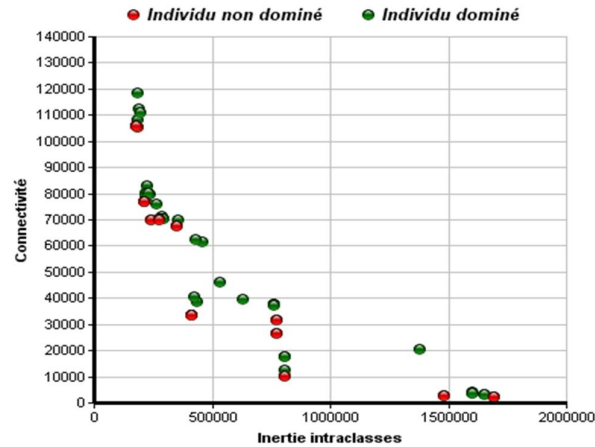


Figure 3.5: Solution de compromis obtenu après 10 générations

3.4 CONCLUSION

Dans ce chapitre nous avons proposé deux approches de segmentation d'images : une approche monoobjectif qui utilise l'inertie intraclasses pour décerner les bon individus, et une approche multiobjectif dont les objectifs sont l'inertie intraclasses-longueur du contour et l'inertie intraclasses-connectivité de pixels. Les performances de ces algorithmes seront discutées dans le prochain chapitre

CHAPITRE 4

APPLICATIONS ET DISCUSSIONS

CHAPITRE 4

APPLICATIONS ET DISCUSSIONS

4.1 INTRODUCTION

Pour évaluer les performances des algorithmes décrits dans notre travail, nous avons procédé à une série de tests, dans un premier temps, sur des images texturées à niveaux de gris tirées de l'album de Brodatz et des images texturées couleur tirées de la base VisTex dont les résultats obtenus sont comparés avec ceux obtenus en utilisant l'algorithme des K-Means. Et dans un deuxième temps, sur des images de télédétection, à savoir : des images Meteosat second génération et SPOT.

4.2 APPLICATION SUR DES IMAGES TEST ISSUES DE L'ALBUM DE BRODATZ ET DE LA BASE VISTEX

Dans cette section, nous appliquons les algorithmes génétiques pour segmenter des images synthétiques constituées d'une mosaïque de textures à niveaux de gris et autres, couleur (figure 4.1). Ces images sont de taille 256 x 256 pixels.




Image 1 : 3 textures




Image 2 : 3 textures




Image 4 : 4 textures




Image 4 : 4 textures



Image 5 : 4 textures couleur




Image 6 : 4 textures couleur

Figure 4.1 : images test texturées

4.2.1 EXTRACTIONS DES ATTRIBUTS DE TEXTURES

Pour extraire les attributs de textures, nous avons utilisé les matrices des cooccurrences (pour $\theta = 0^\circ, 45^\circ, 90^\circ$ et 135°) vu que celles-ci donnent de bons résultats sur la plupart des types d'image [48] [52]. Les fenêtres d'analyse utilisées sont de tailles 5x5, 7x7, 9x9, 11x11 et 13x13, choisies arbitrairement.

Afin d'éliminer les effets directionnels des textures, nous avons calculé la moyenne de chaque propriété texturale extraite dans les différentes directions.

Comme nous l'avons expliqué dans le chapitre précédent, l'utilisation des matrices de cooccurrences est très coûteuse en temps de calcul, pour cela, nous avons effectué une quantification équiprobable à 8 niveaux de gris de chaque image test avant d'en extraire ses attributs. Les résultats de requantification sont illustrés sous forme colorée dans la figure 4.2.




Image 1




Image 2




Image 3




Image 4




Image 5




Image 6

Figure 4.2 : Représentation colorée des images test après quantification équiprobable à 8 niveaux

4.2.2 CHOIX DES ATTRIBUTS DE TEXTURE

Les choix des attributs texturaux qui interviendront dans le processus de classification des pixels s'est fait de manière empirique. Pour faciliter ce choix, nous avons choisi de sauvegarder les attributs sous forme de fichiers XML. Pour obtenir un résultat de segmentation selon un ensemble d'attributs, il suffit de glisser ces derniers sur le fichier exécutable de l'application concernée.

4.2.3 EXTRACTION DE L'INFORMATION SPECTRALE

L'information radiométrique en question est la moyenne (Moy) et la variance (Var) des niveaux des gris en utilisant des fenêtres d'analyse de dimensions $N \times M$. Leurs expressions sont données par les relations suivantes :


$$Moy = \frac{1}{N \cdot M} \sum_{i=1}^N \sum_{j=1}^M I(i, j) \quad (4.1)$$

$$Var = \frac{1}{N \cdot M} \sum_{i=1}^N \sum_{j=1}^M (I(i, j) - Moy)^2 \quad (4.2)$$


Où $I(i, j)$ désigne le niveau du gris du pixel de coordonnées (i, j) ; N et M , respectivement, la hauteur et la largeur de la fenêtre d'analyse.

4.2.4 RESULTATS DE SEGMENTATION


Un échantillon des résultats de segmentation des images tests en utilisant l'algorithme des K-Means, les algorithmes génétiques monoobjectif et multiobjectif est présenté dans la figure 4.3. Ainsi que quelques exemples de leurs performances (figures 4.3, 4.4.a, 4.4.b, 4.5.a et 4.5.b)




(a) (b) (c) (d)
 Résultats de segmentation de l'image 1 avec une fenêtre d'analyse de 5x5




(a) (b) (c) (d)
 Résultats de segmentation de l'image 2 avec une fenêtre d'analyse de 7x7




(a) (b) (c) (d)
 Résultats de segmentation de l'image 3 avec une fenêtre d'analyse de 11x11



(a) (b) (c) (d)
 Résultats de segmentation de l'image 4 avec une fenêtre d'analyse de 11x11



Résultats de segmentation de l'image 5 avec une fenêtre d'analyse de 9x9



Résultats de segmentation de l'image 6 avec une fenêtre d'analyse de 9x9

Figure 4.2 : Résultats de segmentation en utilisant :

- a- les K-Means
- b- l'algorithme génétique monoobjectif (inertie intraclasses)
- c- l'algorithme génétique multiobjectif (inertie intraclasses-longueur du contour)
- d- l'algorithme génétique multiobjectif (inertie intraclasses-connectivité)

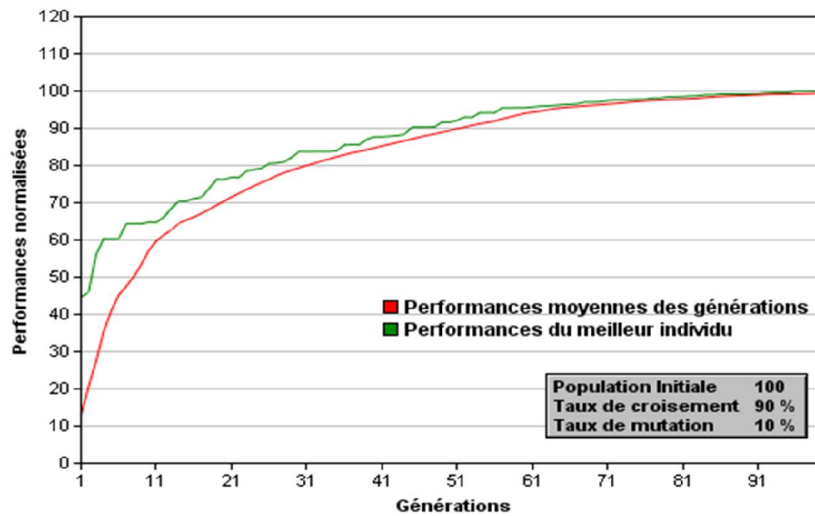


Figure 4.3 : Evolution des performances des individus lors de la segmentation de l'image 2 avec une fenêtre d'analyse de 7x7 en utilisant l'algorithme génétique monoobjectif




Figure 4.4.a : Evolution des fonctions objectif lors de la segmentation de l’image 2 avec une fenêtre d’analyse de 7x7 en utilisant l’algorithme génétique multiobjectif (inertie intraclasse-longueur du contour)

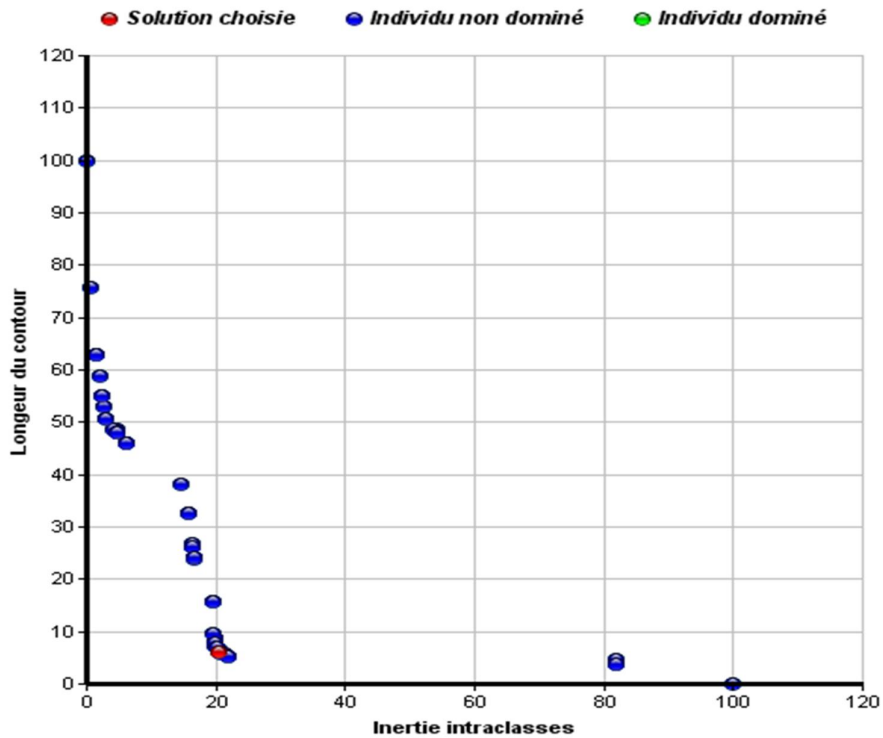


Figure 4.4.b : dernier front de Pareto obtenu lors de la segmentation de l’image 2 avec une fenêtre d’analyse de 7x7 en utilisant l’algorithme génétique multiobjectif (inertie intraclasse-longueur du contour)




Figure 4.5.a : Evolution des fonctions objectif lors de la segmentation de l'image 2 avec une fenêtre d'analyse de 7x7 en utilisant l'algorithme génétique multiobjectif (inertie intraclasses-connectivité)

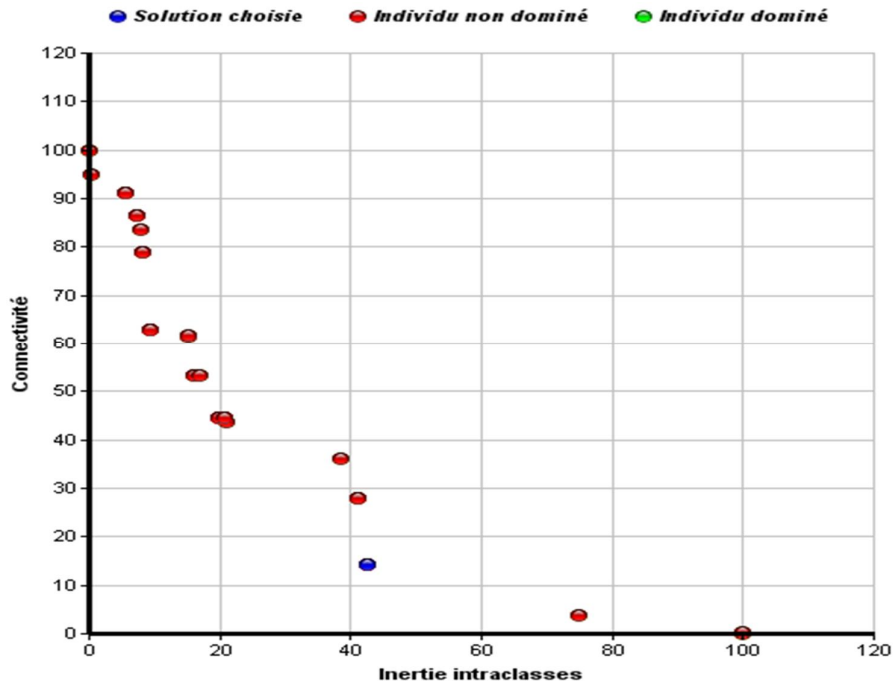


Figure 4.5.b : Dernier front de Pareto obtenu lors de la segmentation de l'image 2 avec une fenêtre d'analyse de 7x7 en utilisant l'algorithme génétique multiobjectif (inertie intraclasses-longueur du contour)

4.2.5 DISCUSSION

D'un point de vue visuel, pour toutes les images tests, les résultats obtenus en utilisant l'algorithme génétique monoobjectif sont presque identiques à ceux obtenu avec les K-Means. Par contre, en utilisant les algorithmes génétiques multiobjectif, les résultats sont nettement meilleurs : il y'a moins de confusion dans la classification des pixels.

Dans la figure 4.2, le résultat de segmentation de l'image 5 par la méthode de k-mens est très mauvais, cela est dû au piégeage de cette dernière dans un minimum local de l'inertie intraclasse. Une réexécution de l'algorithme (K-Means) avec d'autres centres initiaux peut se ramener vers une solution globale.

La figure 4.3 montre que l'algorithme génétique monoobjectif opère à améliorer les solutions courantes de génération en génération jusqu'à ce que tous les individus deviennent presque aussi performants. Ce résultat est dû à la multiplication des meilleurs gènes.

Les algorithmes génétiques multiobjectif opèrent à améliorer les solutions courantes selon leurs deux objectifs simultanément, ce qui est montré par les figures 4.4.a et 4.5.a. Toutefois, l'amélioration des solutions selon un objectif se fait au détriment de l'autre objectif après un nombre donné de générations, ce qui peut être expliqué par le choix d'objectifs contradictoire. Les sorties de ces algorithmes ne sont pas des solutions optimales uniques, mais plutôt, un ensemble de solution qui offrent des bon compromis entre leurs objectifs respectifs (figure 4.4.b, figure 4.5.b).

4.2.6 ÉVALUATION DES RESULTATS

Afin d'évaluer de manière objective les performances des différents algorithmes proposés dans ce travail, nous avons utilisé le taux de bonne classification comme critère d'évaluation.

Le taux de bonne classification est basé sur des connaissances à priori sur les images à segmenter, à savoir, le nombre de régions et la classe d'appartenance de chaque pixel. Il est déterminé par le rapport entre les pixels bien classifiés et le nombre total de pixels de l'image en question.

Le tableau 4.1 illustre les résultats d'évaluation des différentes images tests.

Où ‘Alg. Gén. Monoobjectif ‘ désigne l’algorithme génétique monoobjectif, ‘Alg. Gén. Multiobjectif 1’, l’algorithme génétique multiobjectif (inertie intraclasse-longueur du contour) et ‘Alg. Gén. Multiobjectif 2’, l’algorithme génétique multiobjectif (inertie intraclasse-connectivité).

Image	Algorithme	Taux de bonne classification (%)					Moyenne (%)
		Taille de la fenêtre d’analyse					
		5x5	7x7	9x9	11x11	13x13	
Image 1	K-Means	97.26	98.26	98.35	98.40	98.39	98.13
	Alg. Gén. Monoobjectif	97.26	98.26	98.45	98.51	98.39	98.17
	Alg. Gén. Multiobjectif 1	98.92	99.06	98.28	98.73	98.90	98.78
	Alg. Gén. Multiobjectif 2	98.90	99.05	98.86	98.54	98.77	98.82
Image 2	K-Means	90.13	93.65	94.98	95.63	96.06	94.09
	Alg. Gén. Monoobjectif	90.75	93.65	94.99	95.63	96.06	94.22
	Alg. Gén. Multiobjectif 1	95.51	95.92	95.95	96.23	96.25	95.97
	Alg. Gén. Multiobjectif 2	94.19	96.17	95.81	96.22	96.23	95.72
Image 3	K-Means	83.84	89.26	92.21	93.92	95.50	90.95
	Alg. Gén. Monoobjectif	83.80	89.10	92.31	93.92	96.00	91.03
	Alg. Gén. Multiobjectif 1	84.14	91.12	93.60	95.95	95.67	92.10
	Alg. Gén. Multiobjectif 2	85.91	91.02	92.73	96.03	95.81	92.30
Image 4	K-Means	79.18	83.57	87.25	92.73	92.19	86.98
	Alg. Gén. Monoobjectif	78.73	83.77	87.82	92.60	92.14	87.01
	Alg. Gén. Multiobjectif 1	82.29	87.23	90.43	95.17	92.68	89.56
	Alg. Gén. Multiobjectif 2	84.23	86.84	89.36	95.35	92.58	89.67
Image 5	K-Means	89.76	93.98	62.89	96.74	95.31	87.74
	Alg. Gén. Monoobjectif	89.69	94.07	98.05	96.77	95.20	94.76
	Alg. Gén. Multiobjectif 1	91.30	97.89	99.14	97.92	96.54	97.87
	Alg. Gén. Multiobjectif 2	91.22	97.77	98.83	98.12	95.98	97.68
Image 6	K-Means	80.04	86.73	88.98	87.45	86.93	86.03
	Alg. Gén. Monoobjectif	93.58	94.78	95.13	95.46	96.04	95.00
	Alg. Gén. Multiobjectif 1	95.12	96.34	97.17	97.09	96.88	96.52
	Alg. Gén. Multiobjectif 2	94.99	96.57	97.03	97.18	96.65	96.48

Tableau 4.1 : Résultats de segmentation des images tests en utilisant les attributs de textures extraits des matrices de cooccurrences et les attributs spectraux

4.2.7 DISCUSSION

Le tableau 4.1 confirme le jugement porté sur l'aspect visuel des résultats de segmentation obtenu. En effet, les valeurs maximales des taux de bonne classification de chaque image test pour différentes fenêtres d'analyse sont obtenues en utilisant les algorithmes génétiques multiobjectif jusqu'à atteindre les 99% pour l'image 1 et l'image 5.

4.3 APPLICATION SUR LES IMAGES DE TELEDETECTION

Dans cette section nous allons appliquer les algorithmes génétiques pour segmenter des images Meteosat seconde génération (MSG) et des images SPOT.

4.3.1 APPLICATION SUR LES IMAGES MSG

Les images MSG que nous avons utilisées sont des images prises dans le canal visible (VIS 0.6) et infrarouge (IR 1.6). Elles ont été enregistrées par la station météorologique de l'Office National de Météorologie (ONM) de Dar El Beida (Algérie) au mois de janvier 2006 (figure 4.6). Afin de faciliter la compréhension des résultats obtenus, une composition colorée a été présentée dans la figure 4.7.




Figure 4.6 : Images MSG. a- Image du canal IR 1.6, b- Image du canal VIS 0.6.


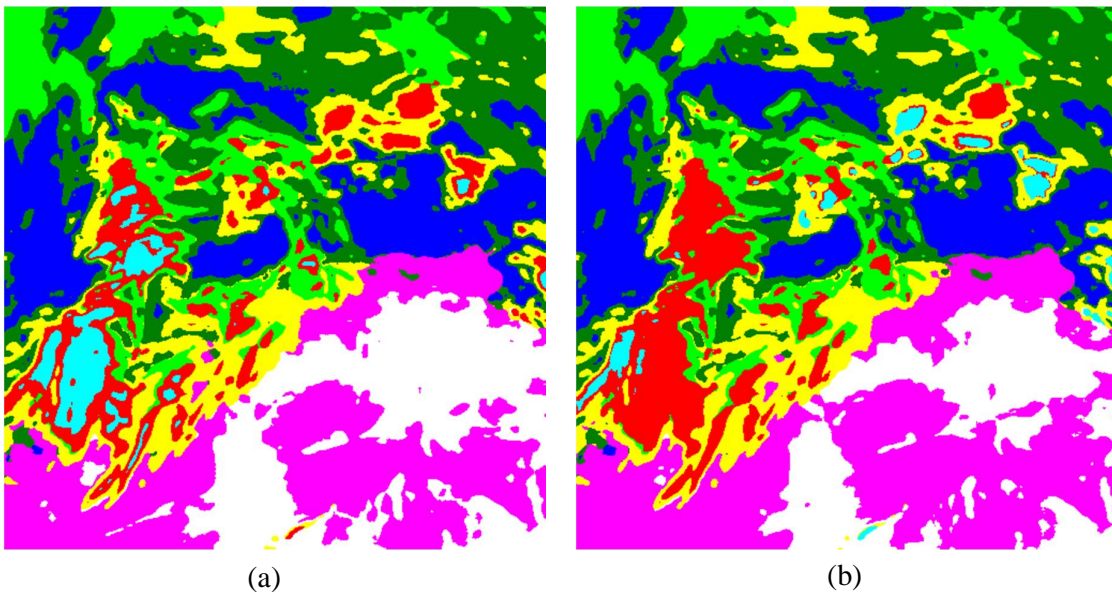



Figure 4.7: composition colorée des deux images MSG

Pour l'obtention des résultats de segmentation, en plus de l'information texturale : contraste et énergie, nous avons intégré dans la procédure de classification l'information radiométrique des deux composantes visible et infrarouge vu que l'étiquetage des pixels qui se base sur l'information texturale seule souffre d'insuffisance de discrimination de l'information pertinente, ce qui empêche d'atteindre un bon niveau de segmentation des régions homogènes [48] [57].

Les résultats de segmentation obtenus sont montrés dans la figure (4.8).





(c)

Figure 4.8: résultats de segmentation en 8 classes en utilisant :

- a- algorithme génétique monoobjectif (inertie intraclases)
- b- algorithme génétique multiobjectif (inertie intraclases-longueur du contour)
- c- algorithme génétique multiobjectif (inertie intraclases-connectivité)

4.3.2 DISCUSSION

Pour apprécier les différents résultats de segmentation obtenus, nous effectuons une comparaison entre ces derniers et la composition colorée de l'image infrarouge et visible. Nous constatons que les couleurs rose et blanche correspondent au sol chaud de l'Afrique du nord ; le vert foncé, dans une majeure partie, au sol froid de l'Europe ; le bleu, à la mer ; et le reste des couleurs représentent les différents types de nuages. La couleur jaune et vert clair semblent représenter des nuages bas et de faible densité, le rouge représente des nuages de forte densité. Dans l'ensemble nous pouvons dire que la classification est bonne pour toutes les méthodes de segmentation proposées.

4.3.3 APPLICATION SUR LES IMAGES SPOT


Nous allons appliquer, dans cette partie, les algorithmes génétiques pour segmenter une image prise par le satellite SPOT 5 de la ville Bratislava, Slovaquie, 2003, avec une résolution de 2.5m (figure 4.9). Pour ce faire, nous avons extrait, dans un premier temps, l'information texturale en utilisant des fenêtres d'analyse de dimensions 5x5 dont on a retenu

les paramètres énergie et contraste. Et puis, dans un deuxième temps, l'information spectrale qui consiste à la moyenne de chaque composante de l'image couleur.

Les résultats de segmentation obtenus sont représentés dans la figure 4.10.



Figure 4.9: Image de de la ville Bratislava, Slovaquie, prise par SPOT 5 en 2003



(a)



(b)



(c)

Figure 4.10: résultats de segmentation en 8 classes en utilisant :

- a- algorithme génétique monoobjectif (inertie intraclasses)
- b- algorithme génétique multiobjectif (inertie intraclasses-longueur du contour)
- c- algorithme génétique multiobjectif (inertie intraclasses-connectivité)

4.3.4 DISCUSSION

Le résultat de segmentation en utilisant l'algorithme génétique monoobjectif est montré sur la figure 4.10.a, nous constatons que les zones agricoles qui semblent être de même nature ont été classifiées sur plusieurs classes ainsi que les forêts. Par contre, en utilisant les algorithmes génétiques multiobjectif (figure 4.10.b, figure 4.10.c), les zones homogènes ont été bien reconnues et sont classifiées dans les mêmes classes.

4.4 CONCLUSION

Dans ce chapitre nous avons présenté les différents résultats de segmentation obtenus en utilisant algorithme génétique monoobjectif dont la fonction objectif est l'inertie intraclasses, et les deux algorithmes génétiques multiobjectif dont les fonctions objectifs sont l'inertie intraclasses-longueur du contour et l'inertie intraclasses-connectivité. Ces derniers convergent toujours vers une solution globale du problème de segmentation, tandis que l'algorithme des K-Means peut être piégé dans une solution locale.

Nous avons montré que l'ajout de l'information spatiale sur l'espace deux dimensions de l'image (la longueur du contour et la connectivité des pixels) améliore la qualité de segmentation d'images.

CONCLUSION ET PERSPECTIVES

CONCLUSION ET PERSPECTIVES

Dans ce travail, nous avons abordé le problème de segmentation d'images au moyen des métaheuristiques ; celles-ci ont révélé leur grande efficacité pour fournir des solutions approchées de bonne qualité sur divers problèmes d'optimisation.

La première étape s'est portée sur la reformulation du problème de segmentation en un problème d'optimisation monoobjectif, dans un premier temps, et multiobjectif, dans un deuxième temps.

La deuxième étape a consisté à l'extraction de l'information spectrale et texturale de l'image. L'extraction de l'information texturale s'est effectuée à l'aide des matrices de cooccurrences. Une requantification équiprobable a été effectuée au préalable dans le but de réduire le temps de calcul. Pour l'information spectrale, nous avons considéré la moyenne et la variance des niveaux de gris sur l'image.

Pour améliorer la qualité de segmentation, nous avons proposé deux approches. La première approche se base sur l'algorithme génétique monoobjectif qui utilise le critère inertie intraclasse pour évaluer la cohésion des classes durant le processus de classification des pixels. Dans la deuxième approche, qui concerne les algorithmes génétiques multiobjectifs, nous avons opté à l'ajout d'un autre critère qui tient compte de l'information spatiale de l'image (longueur du contour, ou, connectivité des pixels). Ainsi, la classification des pixels se fait selon les deux critères simultanément (approche Pareto).

Nous avons montré que l'approche multiobjectif au sens de Pareto améliore considérablement la qualité de segmentation.

La qualité des résultats obtenus en utilisant l'algorithme génétique monoobjectif est du même ordre que celle en utilisant les K-Means. Toutefois, l'algorithme des K-Means ne garantit pas une solution globale du problème de segmentation.

Comme perspective de ce travail, nous pouvons avancer celle d'utiliser l'analyse multi résolution, comme par exemple, la transformée en ondelette, pour l'extraction de l'information texturales vu que la texture peut se présenter sous différentes dimensions.

Une autre perspective, est d'utiliser les métaheuristiques à la segmentation d'une séquence d'images ce qui se ramène à la résolution d'un problème d'optimisation dynamique.

ANNEXES

ANNEXES

LES FICHIERS XML

XML (*Extensible Markup Language*, « langage de balisage extensible») est un langage informatique de balisage *générique*. Cette syntaxe est dite *extensible* car elle permet de définir différents espaces de nom, c'est à dire des langages avec chacun leur vocabulaire et leur grammaire, elle est reconnaissable par son usage des *chevrons* (<>) encadrant les *balises*. L'objectif initial est de faciliter l'échange automatisé de contenus complexes (arbre, texte riche...) entre des systèmes d'information hétérogènes (inter portabilité). Avec ses outils et langages associés une *application XML* respecte généralement certains principes :

- la structure d'un document XML est définie et validable par un schéma.
- un document XML est entièrement transformable dans un autre document XML.

Exemple de fichier XML utilisé dans ce mémoire pour sauvegarder les attributs :

```
<?xml version="1.0"?>
-<opencv_storage>
  -< feautue_mean_6 type_id="opencv-image">
    <width>256</width>
    <height>256</height>
    <origin>top-left</origin>
    <layout>interleaved</layout>
    <dt>f</dt>
    <data> 1.20667715e+001 1.29851036e+001 1.39177189e+001 1.46420145e+001
    1.43819389e+001 1.30375948e+001 1.02969952e+001 6.61251545e+000
    3.92530751e+000 3.20597434e+000 3.61182499e+000 4.29559326e+000
    4.20795393e+000 4.33762074e+000 4.38737392e+000 4.47831488e+000
    4.47764111e+000 4.58246851e+000 4.70140266e+000 4.75803041e+000
    5.14544296e+000 5.65529633e+000 5.44257927e+000 4.71196795e+000
    5.30502987e+000 5.01411533e+000 5.22063398e+000 5.91991901e+000
    6.12269020e+000 6.21023989e+000 6.01154327e+000 5.88513660e+000
    5.84688759e+000 6.22677898e+000 6.49668837e+000 6.90434074e+000
    7.50957203e+000 8.49355221e+000 1....</data>
  </feautue_mean_6>
</opencv_storage>
```

BIBLIOGRAPHIES

Bibliographies

- [1] Shankar, B. U., Novel classification and segmentation techniques with application to remotely sensed images. Lecture note on computer science Series 4400; Transactions on Rough Sets VII Springer Berlin/ Heidelberg, pp. 295-380, 2007.
- [2] Ameer, S. and Ameer, Z., Revue des approches de segmentation d'images texturées: Exemple des images météorologique, 3rd International Conference: Science of Electronic, Technologies of Information and Telecommunication, Tunisia, 2005.
- [3] Guo, D., Atluri, V. and Adam, N., Texture based remote sensing image segmentation. In: Proceeding of IEEE International Conference on Multimedia and Expo, pp. 1472-1475, 2005.
- [4] Wigner, W. and Székely, B., A review on image segmentation techniques with remote sensing perspective. ISPRS TC VII Symposium, Vienna, Austria, Vol. XXXVIII, Part 7A, 2010.
- [5] Canny, John, "A Computational Approach to Edge Detection," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-8, No. 6, pp. 679-698, 1986.
- [6] Herbulot, A., Mesures statistiques non-paramétriques pour la segmentation d'images et de vidéos et minimisation par contours actifs, Thèse de doctorat, Université de Nice, France, 2007.
- [7] Rosenfield, A. and Davis, L.S., Image segmentation and image model. Proceedings of IEEE, 67(5), pp. 764-772, 1979.
- [8] Sezgin, M. and Sankur, B., Survey over image thresholding techniques and quantitative performance evaluation. Journal of Electronic Imaging 13(1), pp. 146-165, 2004.
- [9] Otsu, N., A Threshold Selection Method from Gray-Level Histograms, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 9, No. 1, pp. 62-66, 1979.
- [11] Kapur, J. N., Sahoo, P. K. and Wong, A. C. K., A new method for gray-level picture thresholding using the entropy of the histogram. Computer Vision, Graphics and Image Processing, Vol. 29, pp. 273-285, 1985.
- [12] Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I. and Heynen, M., Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. ISPRS Journal of Photogrammetry & Remote Sensing, 58(3-4), pp. 239-258, 2004.
- [13] Horowitz, S.L. and Pavlidis, T., Picture segmentation by tree transversal algorithm. J. ACM., Vol. 32, 2, pp. 368-388, 1976.

- [14] Hult , R., Grey-level morphology combined with an artificial neural networks approach for multimodal segmentation of the hippocampus. International Conference on Image Analysis and Processing, PP. 277–282, 2003.
- [15] Visa, A., Valkealahti, K. and Simula, O., Cloud detection based on texture segmentation by neural network methods. IEEE International Joint Conference on Neural Networks, 2, pp. 1001-1006, 1991.
- [16] MacQueen, J., Some methods for classification and analysis of multivariate observations. Berkeley Symposium on Mathematical Statistics and Probability, University of California Press, Vol 1, PP. 281-297, 1967.
- [17] Belacel, N., Méthodes de classification multicritères : Méthodologie et applications à l'aide au diagnostic médical , Thèse de doctorat, Université libre de Bruxelles, 2000.
- [18] Dunn, J., A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. Journal of Cybernetics, Vol 3, PP. 32–57, 1973.
- [19] Zadeh, L. A., Fuzzy Sets. Information and Control, 8(3), pp. 338-353, 1965.
- [20] DELENNE c., Extraction et Caractérisation De Vignes à Partir de Données de Télédétection à Très Haute Résolution Spatiale : Application en Languedoc-Roussillon pour la constitution de bases de données géographiques. Thèse de doctorat, Ecole nationale du génie rural, des eaux et des forêts, Montpellier, France, 2006.
- [21] Collete, Y., Siarry. P., Optimisation multiobjectif . Eyrolles, 2002.
- [22] Pareto, V., Cours d'économie politique. Rouge, 1896.
- [23] Nakib. A. Conception de métaheuristiques d'optimisation pour la segmentation d'image. Application à des images biomédicales. Thèse de doctorat. Université de Paris 12-Val de Marne, France. 2008.
- [24] COOREN. y. Perfectionnement d'un algorithme adaptatif d'Optimisation par Essaim Particulaire. Application en génie médical et en électronique. Thèse de doctorat. Université de Paris 12-Val de Marne, France. 2008.
- [25] Ishibuchi, H. and Murata, T., A multiobjective genetic local search algorithm and its application to flowshop scheduling. IEEE Trans on Syst., Man., and Cyber. - Part C: App. and Reviews, Vol. 28, 3, pp. 392-403, 1998.
- [26] Talbi, E.G., Métaheuristiques pour l'optimisation combinatoire multiobjectif: Etat de l'art. CNET. PE: 98-757.33, 1999.
- [27] Schaffer, J. D., Multiple objective optimization with vector evaluated genetic algorithm. In the proceedings of the first Int. Conf. on Genetic Algorithms, pp. 93-100. Pittsburgh (USA), July 1985.
- [28] Collette, Y., Contribution à l'évaluation et au perfectionnement des méthodes d'optimisation multiobjectif. Application à l'optimisation des plans de rechargement de

- combustible nucléaire. Thèse de doctorat. Université de Paris 12, Créteil, Décembre 2002.
- [29] Dréo J., Pétrowski A., Siarry P., Taillard E., *Metaheuristics for hard optimisation*. Springer-Verlag, Berlin Heidelberg, 2006.
- [30] Kirkpatrick, S., Gelatt, C. and Vecchi, M. P., Optimization by simulated annealing. *Science*, Vol. 220, 4598, pp. 671-680, 1983.
- [31] Metropolis, N., Rosenbluth, M. and Teller, A., Teller, E., Equation of state calculation by fast computing machines. *J. of Chemical Physics*, Vol. 21, pp. 1087-1092, 1953.
- [32] Dorigo, M., Maniezzo, V. and colorni, A., Ant System: optimization by a colony of cooperating agents. *IEEE Trans. on Man. Cyber. Part B.*, Vol. 26, 1, pp. 29-41, 1996.
- [33] Monmarché, N., *Algorithmes des fourmis artificielles: applications à la classification et à l'optimisation*. Thèse de doctorat. Université de Tours, Tours, Décembre 2000.
- [34] Dorigo, M. and Blum, C., Ant colony optimization theory: A survey. *Theoretical Computer Sc.*, Vol. 344, pp. 243-278, 2005.
- [35] John Holland. Outline for a logical theory of adaptive systems. *Journal of the Association of Computing Machinery*, 3, 1962.
- [36] BICHOT, C. E. Elaboration d'une nouvelle métaheuristique pour le partitionnement de graphe la méthode de fusion-fission. Thèse de doctorat. Institut national polytechnique de Toulouse, France. 2007.
- [37] Baker, J. E., Reducing bias and inefficiency in the selection algorithm. In Grefenstette, J. J., editor, *Proc. 2nd Int. Conf. on Genetic Algorithms*, pages 14–21, 1987.
- [38] Kenneth A. DE JONG et Jayshree SARMA : Generation Gaps Revisited. In L. Darrell WHITLEY, *Foundations of Genetic Algorithms 2*, p 19–28, 1993.
- [39] Synder, W., Bilbro, G., Logenthiran, A. and Rajala, S., Optimal thresholding– A new approach. *Pattern Recognition Letters*. 1990, Vol. 11, pp. 803-810.
- [40] Sriparna S., anghamitra B. A Multiobjective Simulated Annealing Based Fuzzy-Clustering Technique with Symmetry for Pixel Classification in Remote Sensing Imagery. , *IEEE*, 978-1-4244-2175-6, 2008
- [41] S. Bandyopadhyay, S. Saha, U. Maulik, and K. Deb. A simulated annealing based multi-objective optimization algorithm: AMOSA. *IEEE Transactions on Evolutionary Computation*, 12(3):269–283, JUNE 2008.
- [42] X. Zhang, C. Liu, A Two-Dimensional Image Thresholding Method Based on Multiobjective Optimization, *IEEE*, 978-1-4244-5273-6, 2009

-
- [43] J. Z. Liu and W. Q. Li, The automatic thresholding of gray-level pictures via two-dimensional Otsu method, *Acta Automat. Sinica* (in Chinese), 19, pp.101-105, 1993.
- [44] X. Zhao, M. E. Lee, S.H. Kim, Improved Image Thresholding using Ant Colony Optimization Algorithm, *International Conference on Advanced Language Processing and Web Information Technology*, IEEE ,978-0-7695-3273-8, 2008.
- [45] S. Ghosh, M. Kothari, A. Halder, A. Ghosh, Use of aggregation pheromone density for image segmentation, *Pattern Recognition Letters*, Elsevier, pp. 939–949, 0167-8655, 2009.
- [46] Chun D. N., Yang H. S. Robust image segmentation partition using genetic algorithm with a fuzzy measure, *Pattern Recognition*, Elsevier, vol 29, No 7, pp. 1195-1211, 1996
- [47] S. Shirakawa and T. Nagao, Evolutionary Image Segmentation Based on Multiobjective Clustering , 2009 IEEE Congress on Evolutionary Computation, 978-1-4244-2959-2, 2009
- [48] Ameer S., Analyse de la couverture nuageuse par traitement d'images satellitaires, Thèse de doctorat d'état, université Mouloud Mammeri de Tizi Ouzou, 2000.
- [49] Zhikiang G., Duncan C., Texture and spectral features as an aid to cloud classification, *J. Remote Sensing*, Vol. 12, pp. 953-968, 1991.
- [50] Hammouche K., Methode de classification automatique utilisant la notion de texture. Thèse de doctorat d'état, université Mouloud Mammeri de Tizi Ouzou, 2007.
- [51] A. R. Webb, *Statistical pattern recognition*, 2nd edition John Wiley and Sons, 2002.
- [52] Haralick R.M., Shanmugam K. and Dinstein I., Textural features for image classification, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 3, n° 6, pp. 610-621, 1973.
- [53] Ameer, S ; K. Bara; A. Adane and N. Zerhouni: Effect of the texture anisotropy in the classification of remote sensing images, *Systems Analysis-Modelling Simulation-SAMS*, 2001, Vol.40, pp. 309-327, 2001.
- [54] Gu Z.Q., Duncan C.N., Grant P.M., Cowan C.F.N., Renshaw E. et Muggleston M.A., Textural and spectral features as an aid to cloud classification, *International Journal of Remote Sensing* , vol. 12, n° 5 ; 953-968 pp. ; 1991.
- [55] Sali E. and Wolfson H., Texture classification in aerial photographs and satellite data, *International Journal of Remote Sensing* , vol. 13, n° 18, pp. 3395-3408, 1992.
- [56] Kayitakire F., Giot P. et Defourny P., Discrimination automatique de peuplements forestiers à partir d'orthophotos numériques couleur : un cas d'étude en Belgique, *Journal canadien de télédétection*, vol. 28 ; n° 5, pp. 629-640, 2002.