

Université Mentouri de Constantine

Algorithmes Evolutionnaires pour la Segmentation d'Images basée sur les Champs Aléatoires de Markov

par
Kamal Eddine MELKEMI

Département d'informatique

Thèse de Doctorat en Sciences présentée à la Faculté des sciences de l'Ingénieur
en vue de l'obtention du grade de Doctorat en Sciences
en informatique

Juin, 2006

Université Mentouri de Constantine
Faculté des sciences de l'Ingénieur

Cette thèse intitulée:

Algorithmes Evolutionnaires pour la Segmentation d'Images basée sur les Champs Aléatoires de Markov

présentée par:

Kamal Eddine MELKEMI

a été évaluée par un jury composé des personnes suivantes:

Mohamed Benmohammed
président-rapporteur

Mohamed Batouche
directeur de recherche

Mohamed Khamadja
membre du jury

Mohamed T. Laskri
examineur externe

Hayet Farida Merouani
examinatrice externe

Thèse acceptée le

RÉSUMÉ

Dans ce travail, nous nous intéressons à la segmentation d'images basée sur les Champs Aléatoires de Markov (MRFs) et aux algorithmes évolutionnaires. Dans une première contribution, nous associons le modèle de Bak-Sneppen et les MRFs pour présenter une nouvelle approche de segmentation d'images. En effet, les niveaux de gris des pixels dans l'image sont vus comme des espèces situées dans les nœuds d'une maille du modèle de Bak-Sneppen. Pour chaque espèce nous associons une probabilité a-posteriori. L'évolution du système est basée sur la sélection des espèces inadéquates pour modification. Après un certain nombre d'itérations, le système converge vers un état de haute corrélation appelé *Self-Organized Criticality* (SOC) correspondant à l'estimation Maximum A-Posteriori (MAP). Dans une seconde contribution, nous combinons les MRFs, les Systèmes Multi-Agents (MASs) et les Algorithmes Génétiques (GAs) pour définir une nouvelle approche de segmentation. Dans ce système, nous considérons un ensemble d'agents de segmentation structuré autour d'un agent de coordination dans une architecture de communication en étoile. Les agents de segmentation sont aptes à segmenter une image en utilisant Iterated Conditional Modes (ICM), chacun à partir de sa propre image initiale. Cependant, l'agent de coordination a pour rôle de diversifier les populations de départ, en utilisant les opérateurs génétiques. L'intérêt de cette tâche est d'offrir aux agents de meilleures positions de départ, ce qui leur permet d'accéder aux bonnes configurations. Dans une troisième contribution, nous proposons une approche distribuée hybride de segmentation, dans laquelle l'agent de coordination diversifie les images initiales par croisement génétique et mutation suivis par la recherche locale optimisation extrême. Un système chaotique est introduit avec succès dans les phases d'initialisation et de mutation afin de tirer profit des caractéristiques du chaos telles que la propriété d'ergodicité, l'aspect stochastique et la dépendance à l'égard de l'initialisation.

Mots clés : Champs Aléatoires de Markov, Algorithmes Evolutionnaires, Systèmes Multi-Agents, Segmentation d'images, Optimisation.

ABSTRACT

In this thesis, we are interested in Markov Random Fields (MRF) model-based approaches for image segmentation and Evolutionary Algorithms.

In our first approach, we combine Bak-Sneppen model and MRF to present a new image segmentation method. Image pixels are viewed as lattice species of Bak-Sneppen model with the a-posteriori probability of local fitness. At each discrete run time, some inadequate species are chosen for a random change in their fitness values. Furthermore, the change in fitness of each species engenders a fitness modification in its neighboring species. After a number of iterations, the system converges to a Maximum A Posteriori (MAP) estimate. In the second approach, we propose a new distributed hybrid Genetic Algorithm (GA) using Iterated Conditional Modes (ICM) method for image segmentation also based on MRF. Multi-Agent System (MAS) architecture is used to structure this approach. We consider a set of segmentation agents and a coordinator agent. Each segmentation agent performs ICM starting from its own initial configuration. The coordinator agent diversifies the initial configurations using crossover and mutation. This approach is the hybridization of GAs and MAS. The role of this hybridization is to help in the task of segmentation intensification. In the third contribution, we propose a hybrid distributed image segmentation algorithm structured as a MAS. In fact, the coordinator agent diversifies the initial images using genetic crossover and mutation operators along with the extremal optimization local search. A chaotic system is successfully introduced in the initialization and mutation in order to benefit from the special chaotic characteristic features such as ergodic property, stochastic aspect and dependence on initialization.

Keywords: Markov Random Fields, Evolutionary Algorithm , Multi-Agent System, image segmentation, Optimization.

TABLE DES MATIÈRES

RÉSUMÉ	iii
ABSTRACT	iv
TABLE DES MATIÈRES	v
LISTE DES TABLEAUX	x
LISTE DES FIGURES	xi
LISTE DES SIGLES	xiv
DÉDICACE	xvi
REMERCIEMENTS	xvii
AVANT-PROPOS	xviii
CHAPITRE 1 : INTRODUCTION GÉNÉRALE	1
1.1 Vision et segmentation d'images	1
1.2 Segmentation basée sur les MRFs	2
1.3 Approches proposées pour la segmentation d'images	4
1.3.1 Approche MRF-EO pour la segmentation d'images	4
1.3.2 Approches MAS-GA, MAS-Hybride et CMAS pour la segmentation d'images	5
1.4 Organisation de la thèse	8
CHAPITRE 2 : CONCEPTS DE BASE : PROBLÈME D'ÉTIQUETAGE ET MRFs	9
2.1 Introduction	10
2.2 Les MRFs et processus Markovien	10

2.2.1	Définition d'une image-maille	11
2.2.2	Définition du système de voisinage et cliques	12
2.2.3	Théorème de Hammersley-Clifford	13
2.2.4	Schémas spatiaux	14
2.2.5	Champs aléatoires de Gibbs	17
2.3	Problème d'étiquetage	18
2.4	Modélisation par les MRFs	20
2.4.1	L'estimation Maximum A-Posteriori	22
2.4.2	Modèles d'Ising et Potts	23
2.5	Conclusion	26

CHAPITRE 3 : SEGMENTATION D'IMAGES ET MODÈLES MRFS 27

3.1	Introduction	28
3.2	Algorithmes d'optimisation pour la segmentation basée sur les MRFs	29
3.2.1	L'algorithme SA	29
3.2.2	L'algorithme ICM	31
3.3	Autres approches pour la segmentation d'images	32
3.3.1	Segmentation basée sur les MRFs en utilisant les GAs	32
3.3.2	Segmentation d'images en utilisant les MASs	36
3.4	Conclusion	39

CHAPITRE 4 : UNE APPROCHE DE SEGMENTATION D'IMAGES BASÉE SUR LES MRFS ET LE MODÈLE DE BAK- SNEPPEN 41

4.1	Introduction	42
4.2	Notations, Définitions et Modèles	44
4.2.1	Quelques définitions de base	44
4.2.2	Système de voisinage adopté	44
4.2.3	Le modèle de Bak-Sneppen et l'heuristique optimisation ex- trémale	47

4.3	L'approche MRF-EO pour la segmentation d'images	49
4.3.1	La phase d'initialisation	50
4.3.2	La phase de mise à jour	51
4.4	Résultats expérimentaux	52
4.5	Conclusion	56

**CHAPITRE 5 : UNE APPROCHE ÉVOLUTIONNAIRE DISTRIBUÉE
MAS-GA POUR LA SEGMENTATION BASÉE SUR
LES MRFS 60**

5.1	Introduction	61
5.2	Concepts de base et notations	64
5.2.1	La procédure ICM	66
5.3	Le Concept des Systèmes Multi-Agents	66
5.3.1	Définition de l'agent	67
5.3.2	Autonomie de l'agent	67
5.3.3	De l'agent aux Systèmes Multi-Agents	68
5.3.4	La notion d'environnement	68
5.4	L'architecture du MAS-GA	69
5.4.1	Organisation de notre MAS-GA	70
5.4.2	Coordination	71
5.4.3	Coopération	72
5.4.4	Les opérateurs génétiques	73
5.5	Implémentation et résultats expérimentaux	75
5.6	Conclusion	79

**CHAPITRE 6 : APPROCHES MAS-HYBRIDE ET CMAS POUR
LA SEGMENTATION D'IMAGES BASÉE SUR LES
MRFS 81**

6.1	Introduction	82
6.2	Définitions, notations et modèle MRF utilisé	85

6.3	L'approche MAS-Hybride proposée	86
6.3.1	Description de l'approche MAS-Hybride	86
6.3.2	Applications	88
6.4	Système chaotique	91
6.4.1	Initialisation Chaotique	93
6.4.2	Mutation chaotique	94
6.4.3	Résultats	95
6.5	Conclusion	97
CHAPITRE 7 : CONCLUSION GÉNÉRALE		100
BIBLIOGRAPHIE		104
I.1	Définition d'une probabilité	114
I.2	Définition d'une Variable Aléatoire	115
I.3	Définition d'une fonction de répartition ou distribution	115
I.4	Définition d'une fonction de densité	115
I.5	Définition de l'espérance mathématique	116
I.6	Définition de la variance et de l'écart type	116
I.7	Définition des moments d'une variable aléatoire	116
I.8	Définition de la distribution jointe	117
I.9	Définition de la densité jointe	117
I.10	Définition de la co-variance	117
I.11	Définition de la probabilité conditionnelle	118
I.12	Théorème de la probabilité totale	119
I.13	Théorème de Bayès	119
I.14	Définition de la distribution conditionnelle	120
I.15	Définition de l'independance conditionnelle	120
I.16	Définition de la distribution normale	120
I.17	Définition de la distribution jointe normale	120
I.18	Bruit blanc	122

I.19	Définition : convergence	123
I.20	Définition : convergence dans le sens des moindres carrées	123
II.1	Définition d'un processus stochastique	124
II.2	Définition d'un processus strictement stationnaire et processus faiblement stationnaire	125
II.3	Chaînes de Markov	125
II.3.1	Définition d'un processus markovien	125
II.3.2	Définition d'une chaîne de Markov	126
II.3.3	Propriétés particulières d'une matrice stochastique	127
II.3.4	Propriété d'ergodicité d'une chaîne de Markov	129

LISTE DES TABLEAUX

4.1	Sélection et modification de sites étiquettes $\pi(1)$, $\pi(2)$ et $\pi(4)$	52
6.1	Valeurs minimales de la fonction d'énergie et paramètres des expériences 6.4 et 6.3.	91
6.2	Valeurs minimales de la fonction d'énergie et paramètres des expériences de CMAS.	98

LISTE DES FIGURES

2.1	Système de voisinage et cliques	13
2.2	Segmentation d'images : un problème d'étiquetage.	21
2.3	Modèle d'Ising sur une ligne.	22
2.4	Modèle d'Ising , MRF à 2-D.	23
2.5	Modèle Multi échelle : MRF.	24
3.1	Interprétation par un graphe de la convergence de l'ICM et du SA.	34
3.2	Les opérateurs génétiques : (a) Croisement, (b) Mutation.	35
3.3	Selectionist Relaxation. Les U_s désignent les unités, W_s les fenêtres d'entrée, L_s les étiquettes, N_s les voisinages et B_s désigne les vecteurs de caractéristiques.	36
4.1	Système de voisinage pour Gibbs/MRF.	45
4.2	Structure de la clique pour un système de voisinage second-ordre.	45
4.3	Le modèle de Bak-Sneppen : (a) Cercle, (b) Maille.	48
4.4	Interactions entre les sites étiquettes sur une fenêtre 3×3	52
4.5	Segmentation d'une image synthétique bruitée, (a) Image idéale, (b) Image bruitée, (c) Image segmentée par ICM, (d) Image segmentée par MRF-EO. Paramètres : $\beta = 1.5$, $\tau = 1.4$, $C = 4$	54
4.6	Segmentation d'une image bruitée(64×64), (a) Image observée, (b) Image segmentée par MRF-EO, (c) Image segmentée par ICM, (d) Histogramme de (a). (e) Graphe d'évolution de MRF-EO. Paramètres : $\beta = 1.5$, $\tau = 2.2$, $C = 3$	55
4.7	Exemple d'une segmentation d'une pièce mécanique, (a) Image observée, (b) Image segmentée par MRF-EO, (c) Image segmentée par ICM. Paramètres : $\beta = 1.5$, $\tau = 1.4$, $C = 4$	56
4.8	Evolution de la fonction objective dans la segmentation MRF-EO de la pièce.	57

4.9	Comparaison des fonctions objectives de l'ICM (bleu) et MRF-EO (rouge) pour une segmentation.	58
4.10	Estimation de τ avec différentes exécutions de l'algorithme MRF-EO (pour une même durée).	59
4.11	Segmentation d'une scène réelle. (a) bâtiment (b) image segmentée par MRF-EO (c) image segmentée par ICM.	59
5.1	Exemples de : (A) Systèmes de voisinages, (B) Cliques.	65
5.2	Agents de segmentation à la recherche de l'optimum global.	72
5.3	Topologie en étoile du système.	73
5.4	Réseau de communication.	74
5.5	Crossover de deux parents gris et blanc reproduisant deux descendants "métisses". i_1, i_2 sont les points lignes de croisement et j_1, j_2 sont les points colonnes.	75
5.6	Exemple illustrant l'importance du croisement dans l'amélioration des images initiales.	76
5.7	Résultats de l'application MAS sur une image synthétique avec un nombre d'agents de segmentation=10, nombre d'itérations du MAS=100 et C=3. (a) Image synthétique, (b) image bruitée, (c) Image segmentée par ICM, (d) Image segmentée par MAS, (e) comparaison entre l'ICM et le meilleur agent.	77
5.8	Exemple de reconnaissance de caractère. (a) Image "caractères t_i ", (b) résultat ICM, (c) image segmentée du MAS. Nombre d'agents de segmentation=10, Nombre d'itérations du MAS=70 et C = 2. . .	77
5.9	Segmentation d'une scène réelle. (a) Image d'une pièce, (b) image segmentée du MAS-GA, (c) résultat ICM. nombre d'agents de segmentation=10, nombre d'itérations du MAS-GA=100 et C = 4. . .	78
5.10	Graphe d'évolution de la segmentation du MAS-GA.	78
5.11	Segmentation d'une scène réelle (Maison).	79
6.1	Architecture du MAS-Hybride.	87

6.2	Architecture distribuée sous un modèle d'île.	87
6.3	Application du MAS-Hybride sur une image réelle. (a) image réelle, (b) résultat de l'ICM , (c) résultat du MAS-Hybride (d) Graphe d'évolution de la segmentation.	90
6.4	Application du MAS-Hybride sur une scène naturelle. (a) Image ob- servée, (b) résultat de l'ICM, (c) résultat du MAS-Hybride.	91
6.5	Le "map logistic" et le nouveau "chaotic mapping" crée à partir du neurone chaotique. $\mu = 4$, $k = 300$, $z_0 = 0.01$, $\eta = 0.9$ et $\gamma = 5$	93
6.6	Initialisation chaotique.	94
6.7	Deux sites mutés d'une image initiale. (i_1, j_1) , (i_2, j_2) sont les deux sites mutés.	95
6.8	Segmentation à trois-classes d'une image synthétique bruitée. Nombre d'Itérations du CMAS=100.(a)image idéale (b) image bruitée (c) ICM (d) CMAS.	96
6.9	Segmentation à deux-classes d'une image synthétique bruitée 64×64 . (a) image idéale, (b) image bruitée, (c) résultat de l'ICM, (d) résultat du CMAS.	97
6.10	Une segmentation à deux-classes d'une image bruitée 116×116 . (a) Image bruitée, (b) Résultat de l'ICM (c) résultat du CMAS.	97
6.11	Segmentation à quatre-classes d'un ours. (a) Image de l'ours, (b) résultat de l'ICM, (c) résultat du CMAS.	98
6.12	Segmentation à deux-classes de deux images sonars provoquant un ombrage : (a) d'une roche, et (b) d'un objet cylindrique. (a) image sonar, (b) résultat de l'ICM de (a), (c) résultat de CMAS de (a), (d) image sonar, (e) résultat de l'ICM de (d), (f) résultat de CMAS de (d).	99
I.1	(A) Fonction de densité d'une variable aléatoire normale, (B) Densité jointe de deux variables aléatoires normales.	121
I.2	Deux Images Bruitées	122

LISTE DES SIGLES

MAS	MultiAgent System
CMAS	Chaotic MAS
ICM	Iterated Conditional Modes
MAP	Maximum A-Posteriori
MRF	Markov Random Fields
LP	Labeling Problem
SA	Simulated Annealing
SOC	Self-Organized Criticality
VLSI	Very Large Scale Intergration
SONAR	SOund NAvigation and Ranging
SAR	Synthetic Aperture Radar
IRM	Image à Résonance Magnétique

Bibliographie de l'auteur

Revue avec comité de lecture :

1. K.E. Melkemi, M.C. Batouche and S. Fougou, A MultiAgent System Approach for Image Segmentation using Genetic Algorithms and Extremal Optimization Heuristics, **Pattern Recognition Letters**, special issue on Evolutionary Computer Vision and Image Understanding, **in press and available online**, doi :10.1016/j.patrec.2005.07.021, 2005.

2. K.E. Melkemi, M.C. Batouche and S. Fougou, MRF model-based approach for Image Segmentation using a Chaotic MultiAgent System, WILF'2005 SCIP special session, in I. Bloch, A. Petrosino, and A. G. B. Tettamanzi (Eds.) : Fuzzy Logic and Applications, LNAI 3849, **Revised Selected Papers**, pp. 344-353, 2006, Springer-Verlag Berlin Heidelberg 2006.

Chapitres de livres tirés de conférences internationales avec referees :

1. K. E. Melkemi M.C. Batouche, MRF model-based algorithm using Extremal Optimization, Book Chapter in Advances in Systems Engineering, Signal Processing and Communications, N. Mastorakis Editor, WSEAS 2002, ISPRA2002, Chiclana Spain. pp.115-121, ISBN : 960-8052-69-6.

2. K.E. Melkemi, M.C. Batouche and S. Fougou, MRF and MultiAgent System based Approach for Image Segmentation, IEEE International Conference on Industrial Technology 2004, Hamamat, Tunisia, 8-12 December 2004. IEEE Catalog Number : 04TH8771C, ISBN : 0-7803-8663-9, Vol. 3, pp. 1499-1504.

Conférences nationales :

1. K.E. Melkemi, M.C. Batouche, Une approche pour la segmentation des images en utilisant Optimisation extrême. Journées d'études sur : Vision, Vie Artificielle et Traitement d'images (VVATI'2003), Université de Jijel 2003.

(Dédicace) A la mémoire de mon père

REMERCIEMENTS

Je remercie chaleureusement le Professeur Mohamed Benmohammed pour m'avoir fait le grand honneur de présider le jury.

J'exprime mes remerciements à Mr le Professeur Mohamed Tayeb Laskri, Recteur de l'Université de Annaba pour sa participation à ce jury comme rapporteur malgré ses occupations.

J'adresse tous mes remerciements à Monsieur le Professeur Mohamed Khamadja pour sa disponibilité à juger ce travail.

Mes remerciements vont également à Mme le Docteur Hayet Merouani pour sa participation à ce jury durant cette période sociale.

J'adresse tous mes remerciements à Monsieur le Professeur Mohamed Batouche pour m'avoir encadré, orienté dans ce travail de recherche, m'avoir accordé son soutien et guidé tout au long de ces années. Je lui exprime également toute ma reconnaissance pour m'avoir accueilli dans son équipe de recherche. J'ai ainsi pu apprécier ses qualités humaines, sa bienveillance et la pertinence de ses remarques scientifiques pendant ces années.

Je souhaite également saluer les membres de l'équipe de synthèse d'images du laboratoire LE2I de l'université de Bourgogne, particulièrement le Dr Sebti Fougou qui a contribué de près à la réalisation de ce travail.

AVANT-PROPOS

Ce travail a été réalisé au sein de l'équipe de vision et synthèse d'images au laboratoire LIRE.

Cette thèse est le fruit d'un rapprochement multidisciplinaire qui inclut la théorie des statistiques Bayésiennes, la physique, l'intelligence artificielle distribuée et la génétique. Certains concepts et modèles de la physique ont été repris et introduits afin de définir de nouvelles approches de segmentation.

La combinaison de plusieurs de ces concepts peut offrir une certaine diversité d'approches et élargir le domaine de la segmentation d'images vers de nouvelles perspectives.

Le champ d'application des approches proposées est très varié : on peut citer l'imagerie aérienne générale dont l'étude des végétations, la robotique, l'écologie, la médecine, le militaire, etc...

CHAPITRE 1

INTRODUCTION GÉNÉRALE

1.1 Vision et segmentation d'images

Une scène réelle représentée par une image contient un volume très important d'informations et son traitement exige une élaboration substantielle à tous les niveaux : acquisition, prétraitement, *segmentation*, reconnaissance et enfin interprétation.

Dans la plupart des applications de traitement d'images, les seules contraintes retenues sont essentiellement la qualité et le temps. En analyse d'images, on distingue deux types de traitements : *bas niveau* et *haut niveau*.

Dans le premier, les traitements portent sur les valeurs attachées aux pixels de l'image sans faire le lien avec la réalité qu'elles représentent, tandis que dans le second type, ils opèrent sur des entités symboliques constituant une interprétation de la réalité extraite de l'image.

La segmentation est un traitement bas niveau qui consiste à diviser l'ensemble de pixels en régions disjointes connexes, homogènes, dont l'assemblage correspond exactement à l'image entière. La qualité de l'interprétation d'une image dépend fortement de celle de la segmentation.

La segmentation, sujet difficile, a connu une grande activité de recherche diversifiée en fonction du domaine étudié. Malheureusement, considérant les objectifs, les résultats restent moyens et varient beaucoup en fonction de la technique choisie.

Une méthode de segmentation générale et automatique est difficile à concevoir et à mettre en œuvre en raison de la diversité des scènes à étudier.

Les méthodes de segmentation d'images peuvent être classées en deux grandes classes d'approches : la première est la classification par croissance de régions, la seconde est l'approche stochastique basée sur les modèles Markoviens.

Les méthodes à base des Champs Aléatoires de Markov (MRFs) sont actuelle-

ment largement étudiées et appliquées.

Formellement, une segmentation S d'une image I relativement à un prédicat logique d'homogénéité $Pred$ [HP76] est une partition de I en n ensembles disjoints non vides R_1, R_2, \dots, R_n tels que :

1. $I = \bigcup_{i \in \{1, \dots, n\}} R_i$.
2. $\forall i \in \{1, \dots, n\} R_i$ est un ensemble connexe.
3. $\forall i \in \{1, \dots, n\}, pred(R_i)$ est vrai.
4. $\forall j, k \in \{1, \dots, n\} \quad j \neq k \quad R_j$ est adjacent à $R_k \implies Pred(R_j \cup R_k) = \text{faux}$

Il est important de remarquer que 1, 2, 3 et 4 ne définissent pas une segmentation unique [Mon90]. Afin de trouver une segmentation adéquate parmi les segmentations possibles, on a rajouté une cinquième condition [Mon90].

5. Parmi toutes les segmentations S vérifiant les conditions 1, 2, 3 et 4, nous cherchons celle qui optimise une fonction de qualité.

Cette contrainte réduit le problème d'indétermination de la modélisation donnée par les axiomes 1, 2, 3 et 4.

Parmi ces méthodes figurent celles dite de croissance de régions [HP76, Pav77, Mon87, Bry79, AY81, PSWH84, AAS85, TJ90] où la formation des régions s'effectue d'une manière itérative en utilisant un critère d'homogénéité.

1.2 Segmentation basée sur les MRFs

Dans ce travail, nous nous intéressons à la segmentation d'images. Cette thèse est consacrée particulièrement à la segmentation d'images basée sur les MRFs. D'un point de vue méthodologique, ce travail s'inscrit dans le contexte des méthodes stochastiques pour l'analyse d'images.

La segmentation d'images utilisant les MRFs est l'un des sujets les plus actifs en analyse d'images, en raison du nombre important des travaux qui lui ont été

consacrés, et aux résultats appréciables qu'elle a permis d'obtenir [And99, CJ93, Bou95, ZM97, ZWM98, Li01, LD89, KS80, KZB92, GG84, DJ89, DJNC90, DE87, Bes86, Bes74, BR00]. Cependant, son utilisation nécessite une grande maîtrise tant sur le plan théorique que sur le plan pratique. L'estimation de ses paramètres reste une des tâches les plus difficiles, étant dans la majorité des cas un problème d'optimisation.

Dans le contexte de la segmentation basée sur les MRFs, nous citons deux algorithmes d'optimisation :

Le Recuit Simulé (SA) introduit en 1984 par Stuart et Donald Geman [GG84] et l'Iterated Conditional Modes (ICM) [Bes86].

D'autres méthodes sont basées sur les Algorithmes Génétiques (GAs) comme outil de segmentation d'images. Nous pouvons, en citer les applications dans les papiers [And99, MBP94, BL94, CDPY99, LD89]. Les GAs s'inscrivent dans la classe des heuristiques inspirées de la nature [Hol75, DS95, CDPY99, CP97, Gol89, Koz95, Lev96, LPG94, Sys89, GWB92]. Ce sont des techniques d'optimisation stochastique d'inspiration biologique. Lors du mécanisme biologique crossing over, les chromosomes issus des deux parents s'alignent puis échangent des segments. Les descendants constitués des chromosomes résultant de cette opération combinent de ce fait les caractéristiques des deux parents. Les GAs cherchent à imiter le phénomène d'évolution naturelle des espèces vivantes [Hol75]. Ce phénomène d'évolution repose sur deux mécanismes : la sélection qui fait que seuls les individus les plus aptes survivent et la reproduction qui assure la recombinaison des caractéristiques parentales créant ainsi des descendants aux potentialités nouvelles.

Une approche très intéressante est proposée par Philippe Andrey [AT94, AT98, And99] appelée *selectionist relaxation*. Dans cette approche, l'image à segmenter est considérée comme l'environnement et ses régions déterminées par un critère donné de segmentation représentant des niches. Dans "*selectionist relaxation*" basé sur un GA, chaque chromosome appartient à un certain nombre d'espèces distinctes. Ce processus mène des espèces distinctes à se répartir sur différentes niches. Dans cette méthode, la segmentation émerge progressivement en raison d'un processus

de relaxation principalement conduit par la sélection.

1.3 Approches proposées pour la segmentation d’images

Dans ce travail, nous proposons deux approches pour la segmentation d’images basée sur les MRFs, suivies de deux améliorations de la seconde.

1.3.1 Approche MRF-EO pour la segmentation d’images

La première approche proposée dans cette thèse est une alternative aux méthodes classiques de segmentation d’images. Nous combinons le modèle de Bak-Sneppen et les MRFs pour définir une nouvelle approche de segmentation d’images appelée *MRF-EO*. En effet, les niveaux de gris des pixels sont vus comme des espèces situées dans les nœuds d’une maille du modèle de Bak-Sneppen [BTW87, BS93].

En réalité, nous utilisons l’heuristique *optimisation extrême* [Boe99, BP03] inspirée du mécanisme de Bak-Sneppen [MB02a].

L’une des applications réussies de cette heuristique est la résolution du ‘Graph Bipartitioning’ [BP00] qui est considéré comme un problème combinatoire NP-complet. Par ailleurs, Meshoul et Batouche [MB02b] ont introduit son application dans le domaine de la reconnaissance des formes [MB02b].

Dans notre approche, nous considérons un système maille où chaque nœud correspond à une espèce (pixel, site étiquette, texture, etc...). Nous associons à chaque espèce s la probabilité a-posteriori λ_s , qui représente la valeur objective locale de cette espèce. Cette approche peut être considérée comme une alternative pour l’estimation MAP. Dans ce type de processus, l’évolution du système est basée simplement sur la sélection des *espèces non adaptées* (sites étiquettes) afin de modifier leurs états (classes).

En effet, à chaque cycle d’évolution du système un ensemble de sites étiquettes non adaptés sont choisis pour subir une modification dans leurs valeurs objectives.

D'ailleurs, le changement de la valeur objective d'une espèce (site étiquette) engendre celui des espèces voisines.

Après un certain nombre d'itérations, le système converge vers un état de haute corrélation appelé *Self-Organized Criticality* (SOC). Dans cet état, les espèces se réorganisent dans des catégories, chacune représentant une région (classe) de l'image segmentée.

Notre approche MRF-EO est composée de deux phases principales : *une phase d'initialisation* qui consiste à créer une *configuration initiale* x , et *d'une phase de mise à jour* basée sur la modification de quelques sites étiquettes jugés non adaptés dans la configuration courante.

1.3.2 Approches MAS-GA, MAS-Hybride et CMAS pour la segmentation d'images

Nous nous sommes intéressés, par la suite, à l'utilisation des MASs pour proposer une nouvelle approche de segmentation basée sur les MRFs et les GAs. Dans ce travail, nous notons notre approche distribuée par l'abréviation MAS-GA.

Dans la littérature, nous trouvons peu de travaux utilisant les MASs dans le domaine de l'analyse et la segmentation d'images [DMJ03,PSRa03,RDG03,RRH99,Fer99,Flo98,BG88].

Duchesnay et al. [DMJ03] ont proposé une approche de segmentation d'images basée sur les Systèmes Multi-Agents (MASs). Le concept *agents* qui enrichit le domaine d'analyse d'images permet l'adaptation des traitements locaux aux comportements coopératifs (région/contour) des agents pour trouver les bonnes solutions [DMJ03]. Une autre application des MASs proposée dans le domaine du traitement d'images est présentée par Richard et al. [RDG03]. Cette approche concerne la partie qui traite des tâches de haut niveau dans le système de vision par ordinateur. L'une des autres approches connues utilisant les MASs dans la vision par ordinateur est présentée dans le travail de Rares et al. [RRH99]. Toutes ces approches

sont des applications distribuées composées d’entités, modules indépendants appelés *agents*, ou quelquefois utilisent des techniques d’intelligence artificielle pour réaliser des opérations complexes [RRH99, BG88].

Dans cette nouvelle approche MAS-GA, nous combinons les MRFs, les MASs et les GAs [MBF04]. En effet, notre MAS-GA est vu comme un ensemble d’agents qui coopèrent pour la réalisation d’un objectif local commun, et dans lequel des messages sont échangés dans un ordre coopératif pour l’achèvement d’un objectif global. Dans ce système, nous considérons un ensemble d’agents de segmentation interconnectés à travers un agent de coordination dans une architecture de communication sous une topologie en étoile.

Les agents de segmentation sont capables de segmenter une image en utilisant l’algorithme ICM, chacun à partir de sa propre initialisation.

Cependant, l’agent de coordination joue le rôle de diversification des images de départ, utilisées par les agents de segmentation. Cette tâche est réalisée en utilisant des opérateurs génétiques afin d’accéder aux bonnes configurations. En fait, nous pouvons considérer ce modèle comme une combinaison des GAs et de l’ICM dans le but d’intensifier la recherche de la bonne segmentation.

Dans l’initialisation de l’approche MAS-GA, chaque agent de segmentation crée sa propre image initiale à partir de l’image observée. La procédure d’initialisation est basée sur l’algorithme K-Moyennes avec une légère perturbation aléatoire au niveau de la classification des pixels.

A chaque itération, chaque agent de segmentation utilise l’algorithme ICM pour segmenter l’image à partir de l’image initiale. Après la segmentation et son évaluation en utilisant une fonction d’énergie, chaque agent de segmentation transmet l’image initiale, l’image segmentée, et la valeur de la fonction d’énergie (objective) de la segmentation vers l’agent de coordination. L’agent de coordination reçoit les informations envoyées par les agents de segmentation, conserve la meilleure d’entre elles dans une variable appelée *BestSegmentation*. Ensuite, il applique les opéra-

teurs connus dans les GAs : le croisement et la mutation, sur des images initiales courantes afin d'obtenir une nouvelle population d'images initiales que les agents de segmentation vont utiliser comme points de départ.

Dans cette approche, nous proposons un modèle de coordination dans lequel des agents interagissent et coopèrent pour réaliser leurs propres buts et le but commun. Le résultat de cette coopération est une nouvelle population de configurations sous optimales attribuées aux agents de segmentation. Cette génération de données discrètes initiales permet aux agents de produire une nouvelle génération de segmentations. Etant coopératifs, un ou plusieurs agents de segmentation améliorent le résultat final d'une manière significative. Les agents travaillent ensemble dans un seul système, ce qui nécessite la gestion de plusieurs tâches complémentaires. Les sémaphores sont l'une des solutions utilisées pour résoudre les conflits des activités de coordination.

Nous apportons deux améliorations à l'approche MAS-GA. Dans la première que nous appelons MAS-Hybride, nous introduisons l'heuristique optimisation extrémale ("extremal optimization") comme une recherche locale au niveau du processus génétique juste après la mutation. La combinaison de l'GA avec cette méthode accélère la convergence vers l'optimum globale et améliore la recherche génétique au niveau des étapes finales du cycle d'évolution.

Dans la seconde que nous notons CMAS, nous appliquons un système chaotique dans le but d'améliorer les phases d'initialisation des agents de segmentation et la mutation de l'agent de coordination. Cette approche vise à tirer profit des caractéristiques spéciales du chaos telles que *la sensibilité aux conditions initiales*, *la propriété d'ergodicité*, et *l'aspect stochastique*.

1.4 Organisation de la thèse

Le reste de notre thèse est organisé en six chapitres. Le second chapitre est une introduction aux concepts de base relatifs aux MRFs. Ce chapitre est dédié aux problèmes d'étiquetage, à une classification de ces différentes approches et à la méthode d'estimation MAP.

Dans le troisième chapitre, l'accent sera mis sur les différentes approches de segmentation d'images basée sur les MRFs. Nous commençons à présenter l'ICM et le SA, utilisés comme outils d'optimisation dans la segmentation d'images basée sur les MRFs, suivis des approches principales d'analyse et de segmentation d'images utilisant les GAs et les MASs.

Le quatrième chapitre vise à présenter notre approche de segmentation d'images basée sur la combinaison des modèles des MRFs et de Bak-Sneppen.

Dans le cinquième chapitre, nous proposons une nouvelle approche parallèle évolutionniste distribuée pour la segmentation d'images.

Le sixième chapitre est une présentation de deux approches distribuées de segmentation : la première est hybride, la seconde est chaotique.

Enfin, le dernier chapitre est consacré à la conclusion générale de notre thèse suivie par des perspectives.

CHAPITRE 2

CONCEPTS DE BASE : PROBLÈME D'ÉTIQUETAGE ET MRFS

Dans ce chapitre, nous présentons les concepts de base utilisés dans ce contexte. Nous exposons une introduction aux MRFS qui ont connu une large utilisation dans les domaines d'analyse de séquence. Après avoir introduit le problème d'étiquetage, nous présentons une classification de ces approches. Nous clôturons notre chapitre par une modélisation du problème de la segmentation par les MRFS, en adoptant la méthode MAP qui est largement utilisée.

2.1 Introduction

Dans ce chapitre, nous présentons les principaux concepts de base des MRFs. Nous nous intéressons, en particulier, aux points de vue mathématique et physique des MRFs. La théorie des MRFs a été inspirée par la mécanique statistique (modèle d'Ising). Dans ce travail, nous utilisons les mêmes termes à savoir énergie potentielle, température, etc..., autrement qu'en mécanique statistique.

Par ailleurs, l'accent sera mis sur la méthode d'estimation du Maximum de probabilité A Posteriori (MAP) communément utilisée. Cette méthode MAP qui est largement utilisée est basée sur la théorie de la décision au sens Bayésien. Nous présentons la segmentation par un problème d'étiquetage.

Nous définissons quelques notions comme les processus stochastiques Markoviens, les notions des MRFs, les Champs Aléatoires de Gibbs, les définitions du système de voisinage et des cliques, et les modèles de Potts et Ising etc...

Ce chapitre vise aussi à définir la méthode Maximum de la probabilité A Posteriori (MAP) qui est largement appliquée et qu'on a adoptée dans nos approches.

2.2 Les MRFs et processus Markovien

Le concept des MRFs est une généralisation des processus Markoviens qui ont connu une large utilisation dans les domaines d'analyse de séquence.

Un processus Markovien est défini sur un domaine de temps ou plus précisément, dans un espace temps. Il peut être considéré comme étant une chaîne de séquences de variables aléatoires $\dots, F_1, F_2, \dots, F_m, \dots$ définie par des indices du temps $\dots, 1, 2, \dots, m, \dots$

Un processus markovien unilatéral de n^{ieme} ordre [Li01] vérifie la condition suivante :

$$P(f_i \setminus \dots, f_{i-2}, f_{i-1}) = P(f_i \setminus f_{i-1}, \dots, f_{i-n}) \quad (2.1)$$

Un processus markovien bilatéral ou non causal dépend non seulement du passé mais également du futur. Un processus markovien bilatéral de n^{ieme} ordre [Li01] satisfait la condition suivante :

$$P(f_i \setminus \dots, f_{i-1}, f_{i+1}, \dots) = P(f_i \setminus f_{i+n}, \dots, f_{i+1}, f_{i-1}, \dots, f_{i-n}) \quad (2.2)$$

Soit $F = (F_1, \dots, F_m)$ une famille de variables aléatoires définie sur l'ensemble S , dans lequel chaque variable aléatoire prend une valeur f_i dans \mathbb{L} .

La famille F est appelée un champ aléatoire.

On note l'événement " F_i prend la valeur f_i " par $F_i = f_i$ et on note $F = f$ exprimant l'événement $F_1 = f_1, \dots, F_m = f_m$. Comme abréviation de l'événement joint (joint event), nous utilisons $F = f$ pour des raisons de simplification, où $F_1 = f_1, \dots, F_m = f_m$ désigne une configuration de F correspondant à une réalisation du champ F .

Dans le cas d'un ensemble d'étiquettes discret (par exemple $\mathbb{L} = \{1, \dots, C\}$), la probabilité pour que la variable aléatoire F_i prenne la valeur f_i est $P(F_i = f_i)$ abrégée par $P(f_i)$.

Dans le cas continu, nous utilisons la fonction de densité pour exprimer la probabilité $P(F_i = f_i)$ et $P(F = f)$.

2.2.1 Définition d'une image-maille

Une image $S = \{1, \dots, t, \dots, MN\}$ spécifie les niveaux de gris pour tous les pixels "PICture ELeMent" dans une maille de dimension $M \times N$ ($MN = M \times N$), où t est appelé site.

L'image idéale et observée sont représentées par des vecteurs de variables aléa-

toires comme suit :

Pour l'image idéale par $X = (X_1, \dots, X_t, \dots, X_{MN})$, $X_t \in \{1, \dots, C\}$;

où C désigne le nombre de catégories.

Pour l'image observée par le vecteur aléatoire $Y = (Y_1, \dots, Y_t, \dots, Y_{MN})$, $Y_t \in \{0, \dots, 255\}$

Posons Ω l'ensemble des configurations possibles. Nous supposons que Y est le résultat d'ajout d'un processus bruit à l'image idéale [DJNC90, LD89].

2.2.2 Définition du système de voisinage et cliques

Un système de voisinage $NS = (V_i \subset S, i \in S)$ est la collection des sous-ensembles, V_i de S vérifiant les deux conditions :

(1) $i \notin V_i$ and (2) $j \in V_i \Leftrightarrow i \in V_j$.

Une clique c est un ensemble de points voisins les uns aux autres :

$\forall r, t \in c, r \in V_t$.

Soit $X = (X_1, \dots, X_{MN}) \in \Omega$. On dit que X est un MRF sur S adoptant un système de voisinage NS si :

1. pour tout $x \in \Omega : P(X = x) > 0$
2. $\forall t \in S \quad x \in \Omega : P(x_i/x_j, j \in S - \{i\}) = P(x_i/x_j, j \in V_i)$

$P(X = x) > 0 \quad \forall x \in \Omega$, est appelée condition de **positivité**. Cette condition est supposée pour quelques raisons techniques et peut être habituellement vérifiée en pratique. Par exemple, quand cette condition est satisfaite, la probabilité jointe $P(f)$ de n'importe quel champ aléatoire est uniquement déterminée par ses probabilités conditionnelles locales [Li01, Bes74].

La deuxième condition est appelée (**condition de Markov** ou **Markovianité**). Elle représente les caractéristiques locales du champ X . En effet, une étiquette donnée est en interaction uniquement avec ses voisines. Autrement dit, seules les étiquettes voisines sont en interaction les unes avec les autres. Le choix des dimensions du système de voisinage est fait dans le sens où on conserve l'utilité de la

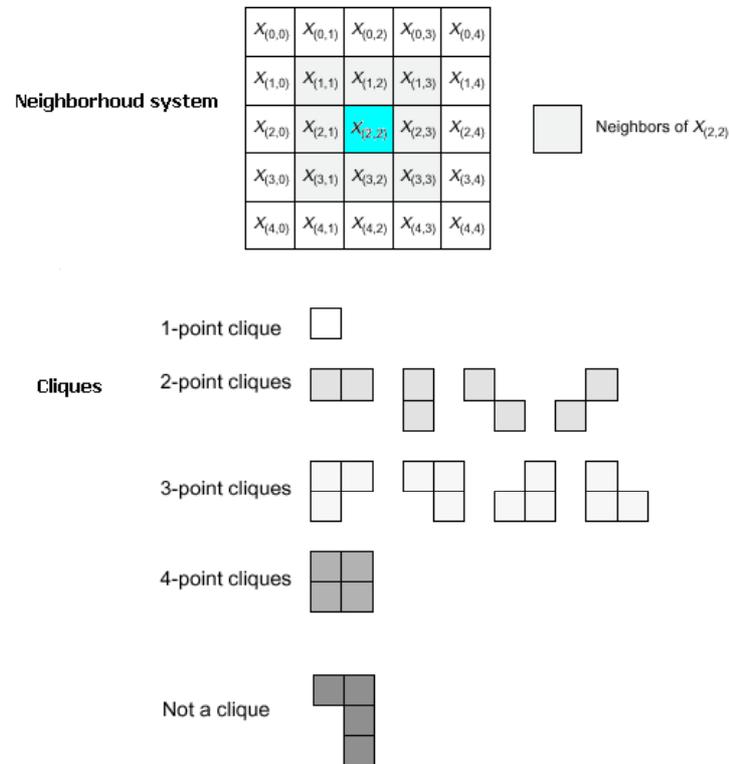


FIG. 2.1: Système de voisinage et cliques

condition de Markov. C'est à dire, si on choisissait un système de voisinage (assez) large, on risque de rendre la condition de Markovianité sans effet notable [Li01].

Chaque MRF X doit respecter un des systèmes de voisinage.

2.2.3 Théorème de Hammersley-Clifford

X est un MRF sur S accordant le système de voisinage NS si et seulement si $P(X = x)$ est une distribution de Gibbs définie par :

$$P(X = x) = e^{-U(x)} / Z \quad (2.3)$$

où $Z = \sum_{x \in \Omega} e^{-U(x)}$ est la fonction de partition et $U(x)$ est la fonction d'énergie donnée par :

$$U(x) = \sum_{t=1}^{MN} \sum_{r \in V_t} \theta_r \delta(x_t, x_r) \quad (2.4)$$

où θ_r sont les paramètres des cliques, $\delta(a, b) = -1$ si $a = b$, 1 sinon $P(X = x)$ est appelée la probabilité a-priori.

2.2.4 Schémas spatiaux

Les schémas spatiaux [Kat94] sont les plus souvent utilisés en traitement d'images. Dans ce cas, nous considérons S comme une grille L telle que $\forall s \in S : s = (i, j)$ et nous définissons les systèmes de voisinage homogènes d'ordre n :

$$V^n = \{V_{(i,j)}^n, (i, j) \in L\}, \quad (2.5)$$

$$V_{(i,j)}^n = \{(k, l) \in L; (k - i)^2 + (l - j)^2 \leq n\}. \quad (2.6)$$

Il est clair que $V^0 = \{(i, j)\}$ et pour tous les $n \geq 0 : V^n \subset V^{n+1}$. Dans la figure 2.1, nous présentons un système de voisinage d'ordre (voir le papier [EDCG84]) 1, 2 etc....

Pour le système de voisinage d'ordre $n = 1$, les cliques sont :

$$\{(i, j)\}, \{(i, j), (i, j + 1)\}, \{(i, j), (i + 1, j)\}.$$

Pratiquement, nous utilisons les systèmes de voisinages d'ordre égal ou inférieur à deux pour des raisons de complexité (fonction d'énergie très complexe à calculer et temps de calcul considérable).

Pour un ensemble de variables qui sont en interaction dans la structure grille, le MRF forme un modèle probabiliste.

Pour un site particulier, sa distribution est fonction du voisinage prédéfini qui l'entoure.

Ceci définit d'une manière claire la propriété de Markovianité du processus.

Celui-ci a une relation spéciale (non causale), respectant cette structure du voisinage particulière.

La question pertinente qui se pose est la suivante :

A chaque site, quelle est la forme la plus probable que $U(x)$ peut prendre afin de donner une structure générale valide du système ?

Le théorème de Hammersley et Clifford publié dans le papier de Julian Besag [Bes74], a donné une réponse qui fait le lien entre le Champ aléatoire de Markov et la distribution de probabilité par $U(x)$ la fonction d'énergie où le Hamiltonien de la distribution de Gibbs donnée par :

$$p(x) = Z^{-1} \times e^{-\frac{1}{T}U(x)} \quad (2.7)$$

où T est une constante associée par analogie à la température et Z la constante de normalisation ou fonction de partition du système.

Le résultat très important de Hammersley et Clifford [Bes74] énonce que :

étant donné une structure de voisinage d'un modèle pour chaque ensemble de sites dans la grille, la distribution commune à la fonction d'énergie de Gibbs est non nulle si et seulement si ces sites forment une clique.

On peut démontrer ce résultat comme suit :

Posons x et x' l'ensemble des états dans ces deux réalisations ayant zéro et non zéro réalisation pour x_i respectivement. Leur rapport peut s'écrire comme suit :

$$\exp\{-U(x) + U(x')\} = \frac{P(x_i/x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n)}{P(x_i = 0/x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n)} \quad (2.8)$$

Un développement polynomial général peut être présenté par la formule sui-

vante :

$$\begin{aligned}
U(x) = & \sum_{1 \leq i \leq n} x_i G_i(x_i) + \sum_{1 \leq i \leq n-1} \sum_{1 \leq j \leq n} x_i x_j G_{ij}(x_i, x_j) + \\
& \sum_{1 \leq i \leq n-2} \sum_{1 \leq j \leq n-1} \sum_{1 \leq k \leq n} x_i x_j x_k G_{ijk}(x_i, x_j, x_k) + \dots \\
& \dots + x_1 \dots x_{i-1} x_i x_{i+1} \dots G_{12 \dots n}(x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n)
\end{aligned} \tag{2.9}$$

où les $G(\cdot)$ sont des fonctions non spécifiées, permettant l'écriture explicite des x_i de l'équation d'énergies 2.8. Par exemple, nous considérons le cas où $i = 1$, la différence en énergie entre le cas où $x_1 = 0$ et $x_1 \neq 0$ sera donnée par :

$$\begin{aligned}
U(x) - U(x') = & x_1 \{ x_1 G_i(x_1) + \sum_{1 \leq j \leq n} x_j G_{ij}(x_1, x_j) + \\
& \sum_{1 \leq j \leq n-1} \sum_{1 \leq k \leq n} x_j x_k G_{1jk}(x_1, x_j, x_k) + \dots \\
& \dots + x_2 \dots x_{i-1} x_i x_{i+1} \dots G_{1 \dots n}(x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) \}.
\end{aligned} \tag{2.10}$$

Dès lors qu'une structure de voisinage existe implicitement dans le modèle associé à la distribution jointe, le résultat de cette différence de termes d'énergie non chutés dans toutes les cliques utilisées doit être nul, alors ces G-fonctions particulières doivent être nulles. N'importe quelle autre G-fonction ayant une forme arbitraire fournissant la condition de positivité pour la distribution de l'ensemble est maintenue ($U(x) > -\infty, \forall x$).

Ce théorème offre une base très générale pour la spécification des fonctions de distributions jointes des champs aléatoires de Markov.

Les modèles d'Ising et Potts et Gaussien des MRFs "Gaussian MRF", sont tous formulés par des auto modèles dans le fameux papier de Julain Besag [Bes74]. Ainsi, leurs fonctions d'énergies prennent la forme générale suivante :

$$U(x) = \sum_{1 \leq i \leq n} x_i G_i(x_i) + \sum_{1 \leq i \leq n-1} \sum_{1 \leq j \leq n} \beta_{ij} x_i x_j \quad (2.11)$$

où β_{ij} sont les paramètres prédéfinis du modèle pouvant exister mais ne décrivant pas nécessairement la dépendance entre les sites.

2.2.5 Champs aléatoires de Gibbs

Dans cette sous-section, nous aborderons les Champs Aléatoires de Gibbs (en anglais "Gibbs Random Fields" (GRF)) respectant un système de voisinage.

\mathbf{F} est un champ aléatoire de Gibbs sur S respectant un système de voisinage NS si sa distribution suit la loi de Gibbs donnée par :

$$p(f) = Z^{-1} \times e^{-\frac{1}{T}U(f)} \quad (2.12)$$

où Z est la fonction de répartition donnée comme suit :

$$Z = \sum_{f \in \Omega} e^{-\frac{1}{T}U(f)} \quad (2.13)$$

La fonction d'énergie $U(f)$ peut être donnée par :

$$U(f) = \sum_{c \in \mathbf{C}} V_c(f) \quad (2.14)$$

$U(f)$ est la somme des cliques potentielles $V_c(f)$ dans \mathbf{C} .

La valeur de $V_c(f)$ dépend de la configuration locale de la clique c . Il est à noter que la distribution Gaussienne est un membre spécial de la famille de cette distribution de Gibbs [Li01].

Un champ aléatoire de Gibbs est dit **homogène** si $V_c(f)$ est indépendant de la position relative de la clique c dans S .

Un champ aléatoire de Gibbs est dit **isotropique** si $V_c(f)$ est indépendant de l'orientation de la clique c .

Il suffit de préciser, si le champ aléatoire de Gibbs est homogène ou isotropique.

2.3 Problème d'étiquetage

Dans le domaine de la vision par ordinateur, Li [Li01] a classifié le problème d'étiquetage (LP : "Labeling Problem") en quatre catégories comme suit :

- LP1 : Sites réguliers avec étiquettes continues.
- LP2 : Sites réguliers avec étiquettes discrètes.
- LP3 : Sites irréguliers avec étiquettes discrètes.
- LP4 : Sites irréguliers avec étiquettes continues.

Les deux premières catégories LP1 et LP2 représentent le traitement bas niveau d'une image observée tandis que LP3 et LP4 donnent le traitement haut niveau représentant les traits et les Caractéristiques extraites du traitement bas niveau.

Dans LP1, on traite notamment par filtrage et lissage le problème de restauration d'image dégradée par un bruit. Cette méthode concerne les images ayant des pixels à valeurs continues. Dans l'étiquetage LP2, on traite la restauration des images binaires ou des images multi niveaux. Aussi, dans la classe LP2 nous trouvons les problèmes de segmentation en régions et de détection de contours.

La classe LP3 concerne les problèmes de la reconnaissance, la comparaison, et le groupement perceptuel à partir des similarités. Dans la catégorie LP4, il s'agit de formuler une estimation à partir d'un nuage de points.

Pour un problème d'étiquetage discret de MN sites, où MN est une abréviation signifiant MN et de C étiquettes, la cardinalité de l'espace des solutions est C^{MN} .

En revanche, dans le cas continu il y a une infinité de solutions. Cependant, on n'en utilise effectivement qu'une partie de cet espace.

Cette recherche est basée sur des critères de mesures d'aptitudes (sélection des bonnes/mauvaises solutions selon une fonction coût ou une fonction objective).

Une image 2D de taille MN représentée sur une grille rectangulaire est définie ainsi :

$$S = \{S(i, j) \in \{0, \dots, 255\}; i \in \{1, \dots, N\} \text{ et } j \in \{1, \dots, M\}\} \quad (2.15)$$

où $s(i, j)$ désigne le niveau de gris codé entre 0 et 255.

La représentation linéaire de S est comme suit :

$$S = \{s, s \in \{1, \dots, MN\}\} \quad (2.16)$$

Les sites de la grille S sont les indices qui sont considérés comme spatialement réguliers. Les interconnexions entre les sites sont caractérisées par le système de voisinage.

Une **étiquette** est considérée comme un évènement qui peut se produire dans un **site** [Li01]. Nous notons par L l'ensemble des étiquettes. Un ensemble d'étiquettes peut être classé dans les continus ou les discrets. Dans le cas continu, une étiquette peut correspondre à une ligne droite \mathbb{R} ou à un intervalle compact.

$$L_c = [X_l, X_h] \subset \mathbb{R} \quad (2.17)$$

Dans le cas discret, l'étiquette prend une valeur discrète dans un ensemble de C étiquettes.

$$L_d = \{l_1, \dots, l_C\} \quad (2.18)$$

ou simplement

$$L_d = \{1, \dots, C\} \quad (2.19)$$

En détection de contour, par exemple, $L_d = \{\text{contour}, \text{non - contour}\}$.

Dans des cas discrets, nous représentons l'ensemble d'étiquettes par $\{0, \dots, 255\}$ donnant les valeurs des intensités.

Puisque ces valeurs représentent des intensités, nous avons alors un ensemble d'étiquettes ordonné $0 < 1 < \dots < 255$. Lorsque cet ensemble désigne 256 codes (comme certains types de textures), il est considéré comme non ordonné sauf dans le cas où un ordre quelconque (artificiel) est imposé.

Pour un étiquetage, une valeur numérique (quantité) peut être définie comme mesure de similarité entre n'importe quel couple ou voisinage d'étiquettes.

En conséquence, le problème de segmentation d'images peut être interprété comme une optimisation d'étiquetage (voir Figure 2.2).

2.4 Modélisation par les MRFs

Le concept des MRFs est le résultat de plusieurs tentatives de mettre un modèle dit Ising dans un cadre probabiliste général. L'origine de cette formulation est due aux travaux d'Ising [KS80]. Le modèle d'Ising considère une séquence $0, \dots, i, \dots, a$ de sites sur une ligne (voir Figure 2.3). A un instant donné, chaque site est en position haute désignant un petit dipôle ou basse désignant un épine. Nous considérons une configuration $w = (w_0, \dots, w_i, \dots, w_a)$. Cette configuration est un MRF où $w_i = +$ si le site i est dans une rotation vers la position haute et $w_i = -$ si le site i est dans une rotation vers la position basse (voir Figure 2.3).

Dans le modèle d'Ising, nous définissons une mesure de probabilité sur toutes les configurations possibles. Nous associons une fonction d'énergie tenant compte des interactions voisines et de la propriété externe magnétique du champ [KS80].

Ce modèle est applicable aussi sur la maille bidimensionnelle où des rotations

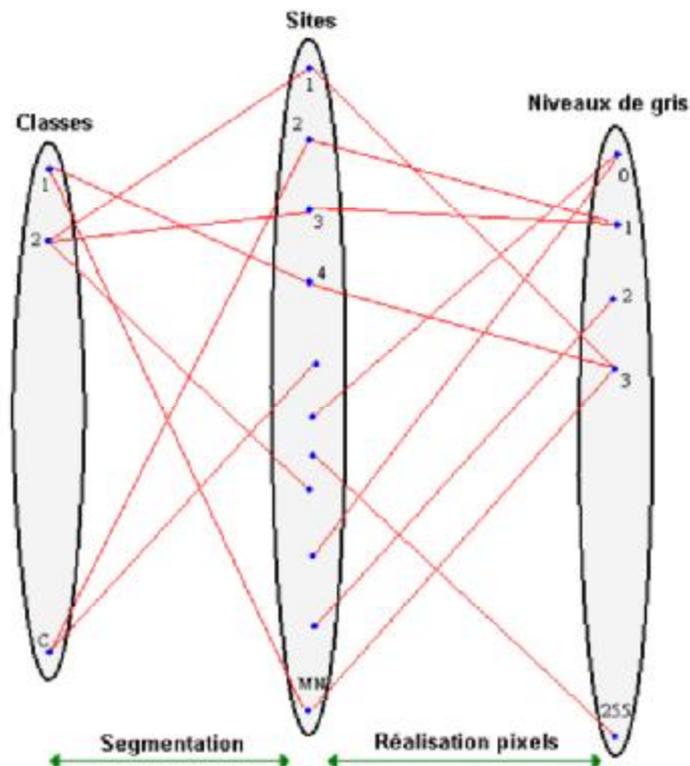


FIG. 2.2: Segmentation d'images : un problème d'étiquetage.

sont effectuées sur des emplacements ou des sites de la maille.

Soit une image S associée à une maille de taille MN sites (cf. 2.15,2.16).

Dans notre étude, nous associons à chaque site s deux variables aléatoires X_s et Y_s dont les valeurs x_s et y_s appartiennent à L_d et $\{0, \dots, 255\}$ où :

L'ensemble $L_d = \{1, \dots, C\}$ désigne les étiquettes et C le nombre de classes.

L'ensemble $\{0, \dots, 255\}^q$ représente les niveaux de gris susceptibles d'être associés à un pixel d'une scène multispectrale à q canaux. L'image est donc considérée comme un champ aléatoire X donné par $X=(X_s, s \in S)$ dont le vecteur de valeurs $x = (x_s, s \in S)$ est appelé une configuration ou une réalisation. Une configuration est un élément de l'espace produit Ω^{MN} appelé espace de population, où Ω^{MN} est l'ensemble des configurations possibles.

De même, une image observée (bruitée par exemple) est représentée par le

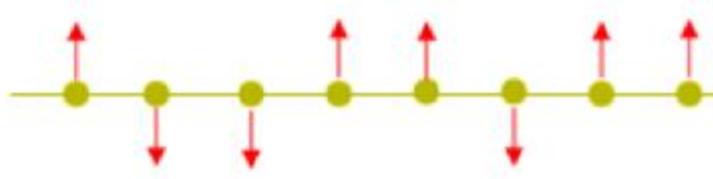


FIG. 2.3: Modèle d'Ising sur une ligne.

champ aléatoire $Y = (Y_s, s \in S)$. Ce vecteur $y = (y_s, s \in S)$ est appelé réalisation de pixels.

2.4.1 L'estimation Maximum A-Posteriori

Dans cette partie, nous présentons l'approche maximum A-Posteriori (MAP) de segmentation basée sur les MRFs. Cette technique qu'on va appliquer est souvent la plus utilisée dans la littérature.

Alors, l'objectif de notre travail est de chercher une configuration x^* qui maximise la probabilité a-posteriori (MAP) $P(x|y)$.

On a :

$$P(x|y) = \frac{1}{P(y)} P(x|y) P(y) \quad (2.20)$$

Nous remarquons que $P(y)$ ne dépend pas de l'étiquetage x et nous supposons que :

$$P(x|y) = \prod_{i \in S} P(x_i/y_i) \quad (2.21)$$

L'étiquetage recherché sera donné par :

$$x^* = \underset{x \in \Omega}{\operatorname{argmax}} \prod_{i \in S} P(x_i/y_i) \prod_{k \in C} e^{-V_k(x_i)} \quad (2.22)$$

La probabilité a-posteriori $P(x|y)$ suit la distribution de Gibbs donnée par la formule :

$P(x/y) = e^{-U(x/y)}/Z_y$ où Z_y est la constante de normalisation et $U(x/y)$ est la fonction d'énergie [KZB92, Kat94] donnée par l'équation :

$$U(x/y) = \sum_{t=1}^{MN} \left[\ln(\sqrt{2\pi}\sigma_{xt}) + \frac{(y_t - \mu_{xt})^2}{2\sigma_{xt}^2} + \sum_{r \in V_t} (\beta \delta(x_t, x_r)) \right] \quad (2.23)$$

où β est le paramètre du modèle ($\beta > 0$) contrôlant l'homogénéité des régions dans l'image.

2.4.2 Modèles d'Ising et Potts

La modélisation d'une image est l'étude des interactions entre les sites étiquettes dans un modèle hiérarchique. Dans cette modélisation, un processus spatial est requis afin de réaliser la classification des étiquettes identiques entre sites voisins dans une grille. Le modèle de Potts offre ces fonctions dans sa partie de segmentation d'images. Pour mieux comprendre leur fonctionnement il est nécessaire de commencer par examiner leurs relations binaires dans le modèle d'Ising.

2.4.2.1 Modèle d'Ising

Pour un modèle d'Ising associé à un MRF 2-D [Bou95], nous prenons les deux cliques présentées dans la figure 2.4.



FIG. 2.4: Modèle d'Ising , MRF à 2-D.

Les fonctions potentielles sont données par 2.24 :

$$V(x_r, x_s) = \beta \cdot \delta(x_r \neq x_s) \quad (2.24)$$

où β est le paramètre du modèle.

La fonction d'énergie est donnée par la formule suivante :

$$V_c(x_c) = \beta(\text{Frontiere} \quad \text{Longueur}) \quad (2.25)$$

2.4.2.2 Modèle multi-échelle

Dans la Figure 2.5, nous présentons le modèle multi-échelle [Bou95] associé à un MRF [Bou95] ; nous prenons les quatre cliques représentées par les couleurs verte dans la Figure 2.5 (horizontales et verticales, noté par \mathbf{C}_1), et bleu (Diagonales, noté par \mathbf{C}_2).

On définit les cliques \mathbf{C}_1 et \mathbf{C}_2 comme suit :

$\mathbf{C}_1 = (\text{CliquesHorizontales/Verticales})$ et $\mathbf{C}_2 = (\text{CliquesDiagonales})$.

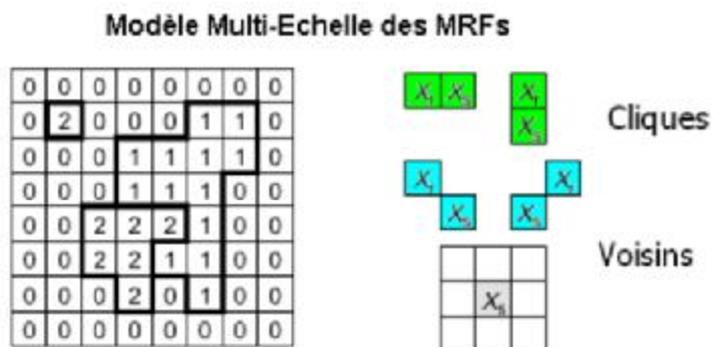


FIG. 2.5: Modèle Multi échelle : MRF.

Donc, les fonctions potentielles sont données par :

$$V(x_r, x_s) = \beta_1 \cdot \delta(x_r \neq x_s) \quad \text{pour} \quad \{r, s\} \in C_1 \quad \text{et} \quad \beta_2 \cdot \delta(x_r \neq x_s) \quad \text{pour} \quad \{r, s\} \in C_2 \quad (2.26)$$

où β_1, β_2 sont les paramètres du modèle.

On définit deux sommes t_1 et t_2 comme suit :

$$t_1(x) = \sum_{\{r,s\} \in C_1} \delta(x_r \neq x_s) \quad \text{et} \quad t_2(x) = \sum_{\{r,s\} \in C_2} \delta(x_r \neq x_s)$$

Alors la probabilité est donnée par :

$$P(x) = \frac{1}{Z} \exp\{-(\beta_1 \cdot t_1(x) + \beta_2 \cdot t_2(x))\} \quad (2.27)$$

Nous définissons la segmentation d'images comme étant l'estimation d'une configuration x qui minimise la fonction d'énergie $U(x/y)$.

Nous appelons cette approche **estimation MAP**.

En effet, le problème est l'estimation d'une configuration d'étiquettes x à partir d'une réalisation pixel y .

La segmentation d'images basée sur les MRFs est une tâche très complexe. Ceci est dû au besoin de définir l'estimation MAP de la distribution multidimensionnelle de Gibbs, ce qui devient un problème d'optimisation NP-complet.

Dans ce contexte, nous citons deux algorithmes d'optimisation très utilisés pour l'estimation du MAP :

Le SA introduit en 1984 par Stuart et Donald Geman [GG84] et l'ICM de Julian Besag en 1986 [Bes86]. D'autres méthodes basées sur les GAs sont proposées [Hol75, Gol89, AT94, KPK00]. Théoriquement, le SA converge vers l'optimum global [GG84]. Malheureusement, il reste un algorithme coûteux en matière de temps de calcul dans la segmentation d'images.

Par ailleurs, l'approche ICM est utilisée comme une méthode déterministe de segmentation d'images. A partir d'une configuration sous-optimale, l'ICM maximise la probabilité du champ de la segmentation par un changement itératif et

déterministe des classifications de pixels. L'ICM est très efficace sur le plan temps de calcul [DJNC90], cependant il dépend de la phase initialisation et converge vers un optimum local.

2.5 Conclusion

Dans ce chapitre, nous avons présenté un ensemble de concepts de base qu'on va utiliser dans ce travail. Nous nous sommes intéressés, essentiellement, à la théorie de la décision au sens Bayésien qui est la base de l'estimation du MAP largement appliqué dans l'étiquetage d'images. L'utilisation des champs aléatoires de Markov est très répandue depuis le travail d'Ising. Elle a été adoptée en analyse d'images depuis la publication des résultats de Stuart et Donald Geman en 1984.

Nous avons présenté dans ce chapitre les concepts fondamentaux de la théorie des champs markoviens comme une généralisation des chaînes de Markov. Nous avons défini les MRFs par des modèles spatiaux et présenté, par la suite, une classification des différents types de problèmes de visions modélisés comme problèmes d'étiquetages.

Par ailleurs, nous nous sommes intéressés à la modélisation par les MRFs, les modèles d'Ising et Potts puis enfin nous avons présenté la méthode d'estimation MAP.

CHAPITRE 3

SEGMENTATION D'IMAGES ET MODÈLES MRFS

Dans ce chapitre, nous présentons un état de l'art sur les approches de segmentation d'images. Nous nous sommes intéressés aux approches de segmentations d'images basée sur les MRFS. Après avoir exposé les concepts théoriques dans le chapitre précédent, nous apportons une vue des outils d'optimisation utilisés dans la segmentation d'images basée sur les MRFS. Nous introduisons un ensemble d'approches d'analyse et de segmentation d'images utilisant les GAs, les MASs etc..

3.1 Introduction

En analyse d'images le domaine de l'estimation et de la décision est basé essentiellement sur la théorie des statistiques Bayésienne. Cette théorie postule que si on connaît la distribution *a-priori* ainsi que la fonction de vraisemblance de la forme, l'étiquetage Bayésien devient la connaissance pour estimer la meilleure de ces informations sources [Li01].

La méthode d'estimation MAP, un cas particulier dans la théorie Bayésienne [Li01], est utilisée dans plusieurs travaux de vision.

Depuis la publication du travail de Stuart et Donald Geman [GG84], l'utilisation des MRFs est devenue très populaire en analyse d'images et de nombreux chercheurs lui ont consacré leurs travaux. Le lecteur peut se reporter aux articles [GM85, DE87, GG86, DJ89, Bes86, Bes89, AT94, AT98, And99].

La projection du problème de la segmentation dans un contexte stochastique s'avère donc, prometteuse. Sa nouvelle formulation permet à la fois de modéliser les textures dans la forme où elles sont présentées, et les déformations subies lors de l'acquisition dont on dispose théoriquement.

En analyse d'images, les algorithmes utilisant les modèles Markoviens sont souvent destinés à un domaine spécifique (images SAR (synthetic aperture radar), images IRM (image résonance magnétique), images aériennes de végétation, images sous-marines, etc...).

Un cadre général dans la vision par ordinateur est l'étiquetage d'images où nous voulons faire une correspondance entre étiquettes et pixels. La perception de cette étiquette dépend de l'application.

Par exemple, dans la restauration d'images, l'étiquette représente le niveau de gris, dans la détection de contour elle indique la position et la direction d'un point de contour et dans la segmentation d'images elle code la classe ou la région.

Le problème est d'établir une correspondance entre étiquettes et pixels. Il s'agit d'associer pour chaque pixel dans l'image l'étiquette la plus appropriée (la plus probable). Pour cela, nous avons besoin de définir une mesure de probabilité sur

l'ensemble des étiquetages possibles. Dans les images réelles, les pixels voisins ont souvent une intensité similaire. Cette régularité est modélisée par les MRFs.

Pour ce problème de segmentation basée sur les MRFs, nous utilisons le modèle markovien du type basé sur la distance et non pas sur le temps, le processus markovien étant sans mémoire. Le théorème de *Hammersley-Clifford* offre un avantage très important pour leur utilisation. En effet, il permet de définir les champs markoviens par des énergies potentielles.

Dans ce contexte, le choix des outils d'optimisation dans un cadre conceptuel s'avère très important. Nous présentons dans ce chapitre deux algorithmes populaires d'optimisation : le SA et l'ICM. Nous pouvons classer ces approches de segmentation comme suit : approches basées sur les méthodes ICM ou SA (amélioration des deux algorithmes); approches ad hoc; approches basées sur les GAs et approches utilisant des techniques d'intelligence artificielle distribuée (MAS).

3.2 Algorithmes d'optimisation pour la segmentation basée sur les MRFs

3.2.1 L'algorithme SA

L'idée de simuler sur ordinateur le processus du recuit du cristal est avancée par Metropolis et al. [MRR⁺53].

L'application de cette idée dans les problèmes d'optimisation combinatoire vient un peu en retard dans les travaux de Kirkpatrick et al. [KGV83]. Le SA [KGV83] consiste à déterminer la solution optimale pour un problème posé sous forme d'un système physique imaginaire. Dans cette heuristique, nous utilisons l'algorithme de Metropolis à chaque séquence de diminution de température. Cette séquence est appelée "programme du recuit : en anglais annealing schedule". Ce programme du recuit [KGV83] est fondé sur une recherche ad hoc utilisant une séquence inspirée d'un phénomène chimique.

L'utilisation d'un algorithme déterministe (gradient par exemple) pour minimiser une fonction F non convexe peut donner de très mauvais résultats (dans le cas où la fonction comporte beaucoup de minima locaux, on est à peu près certain de

buter l'un d'eux).

En utilisant une exploration aléatoire de l'espace d'état, la stratégie du SA consiste à favoriser les descentes, mais sans interdire tout à fait les remontées. Plus précisément, on se donne une chaîne de Markov sur l'espace d'états, et nous choisissons la transition vers l'un d'eux selon la probabilité $\exp(-\frac{\Delta F}{T})$. C'est à dire, nous acceptons ou nous refusons une transition avec une probabilité 1 si F décroît, et une probabilité égale à $\exp(-\frac{\Delta F}{T})$ si F croît. T est la température.

On peut voir que plus la température T est élevée, plus aisées seront les transitions ascendantes. A la limite $T = 0$, nous obtenons un algorithme de descente. Tout au long de l'algorithme, nous décroissons T , ni trop vite pour ne pas rester bloqué autour d'un minimum local, ni trop lentement si nous voulons avoir un résultat en un temps raisonnable.

L'application du SA dans la segmentation d'images basée sur les MRFs est obtenue grâce à l'approche de Stuart et Donald Geman [GG84] dans laquelle l'existence du programme de recuit est prouvée théoriquement, ce qui n'est pas le cas dans la version de Kirkpatrick [KGV83]. En plus, la convergence du processus vers un optimum global est démontrée. On trouve dans le travail de Van Laarhoven et al. [LA87] une étude complète des aspects de cette heuristique du SA.

Le SA peut être présenté par l'algorithme 1.

Algorithme 1 Le SA.

- 1) **Générer** une *configuration initiale* x^* aléatoirement, Posons $T = T_0$.
 - 2) **Perturber** x^* dans z^* : sélectionner un pixel et **Affecter** aléatoirement une nouvelle étiquette. $D = U(z^*/y) - U(x^*/y)$ **Si** $D < 0$ **lors** Poser $x^* = z^*$
Générer m uniformément distribué dans $[0, 1]$; **Si** $m < e^{(-D/T)}$ **alors** Poser $x^* = z^*$;
 - 3) **Répéter** l'étape (2) N_{inner} Itérations
 - 4) **Poser** $T = f(T)$ où f est une fonction strictement décroissante.
 - 5) **Répéter** les étapes (2)..(4) Jusqu'à la stabilité du système.
-

La fonction f représente la vitesse de refroidissement "the cooling schedule". Par exemple, on peut prendre : $f(T) = \alpha.T$, tel que, $0 < \alpha < 1$, (α proche de 1).

D'une façon expérimentale, nous choisissons T_0 , le nombre des boucles locales N_{inner} , le nombre d'itérations pour simuler le processus du recuit. Pour éviter les optima locaux, nous sommes dans l'obligation d'adopter un rythme modéré à la décroissance de température.

3.2.2 L'algorithme ICM

L'*ICM* est proposé comme une méthode déterministe de segmentation d'images basée sur les MRFs. Elle peut être considérée comme une alternative pour l'estimation du MAP. Cette approche est introduite par Julian Besag [Bes86]. Commencant par une image classifiée sous-optimale, l'idée principale de l'*ICM* est de mettre à jour chaque pixel t qui correspond au minimum de l'énergie locale $U(x_t/x_r, r \in V_t)$.

La condition de stabilité de l'approche *ICM* peut simplement être obtenue par le calcul du nombre des mises à jour. L'arrêt du processus se fait quand ce nombre est nul ou suffisamment faible. L'algorithme de l'*ICM* est présenté par le code 2.

Algorithme 2 L'ICM.

- 1) **Choisir** une configuration X^0 aussi près que possible de la configuration optimale.
 - 2) **Balayer** l'ensemble des sites étiquettes. Chaque site t visité à l'étape n est caractérisé par son état $x^{(n)}$ et par la configuration de son voisinage $V_t^{(n)}$. Son nouvel état $x^{(n+1)}$ est la valeur correspondant au maximum de la probabilité a-posteriori $P(. / x_r^{(n)}, r \in V_t^{(n)})$.
 - 3) **Répéter** l'étape 2. un nombre d'itérations ou **Jusqu'à** ce qu'une condition d'arrêt est vérifiée.
-

Pappas [Pap92] a présenté une méthode Markovienne de segmentation. Cette méthode modélise l'image comme une collection de régions dont l'intensité est uniforme ou à faible variation. Le modèle a priori utilisé pour caractériser l'image segmentée suit une distribution de Gibbs. Un bruit blanc Gaussien est choisi pour la probabilité a posteriori modélisant le bruit. L'optimisation de la fonction d'énergie est basée essentiellement sur l'algorithme ICM adapté à l'approche.

3.3 Autres approches pour la segmentation d'images

3.3.1 Segmentation basée sur les MRFs en utilisant les GAs

Les GAs [Hol75, Gol89] ont été introduits par John Holland en 1975 [Hol75] comme outil puissant d'optimisation. Cette heuristique s'appuyant sur le principe d'évolution naturelle des espèces a connu beaucoup d'applications.

Les GAs s'inspirent de l'évolution génétique des espèces ; ils copient de façon extrêmement simplifiée certains comportements des populations naturelles. Ainsi, ces heuristiques reposent toutes sur le principe de Charles Darwin :

"the survival of the fittest".

Dans ces techniques, l'évolution d'une population de solutions se produit sous l'action de règles précises optimisant un comportement donné, exprimé sous forme d'une fonction, dite fonction adaptative à l'environnement [Lut99].

A chaque itération, une génération est créée comme une nouvelle population avec le même nombre de chromosomes.

Cette génération sera composée des chromosomes mieux *adaptés*. Après un certain nombre d'itérations, les chromosomes générés vont tendre vers l'optimum de la fonction objective. La création d'une nouvelle population à partir de la précédente se fait par application des opérateurs génétiques : sélection, croisement et mutation.

La sélection est la première opération, dans laquelle le processus choisit les éléments pertinents qui optimisent mieux la fonction. Le croisement permet de générer deux chromosomes nouveaux (*descendants*) à partir de deux chromosomes sélectionnés (*parents*) (voir la Figure 3.2.(a)).

La mutation inverse un ou plusieurs gènes dans un chromosome sélectionné (voir Figure 3.2.(b)).

Il est à noter que le croisement réalise des *échanges globaux* de segments, tandis que la mutation effectue des *changements profonds* au niveau local du matériel

génétique, ce qui permet de débloquent l'évolution.

Un algorithme génétique de base peut s'écrire par le code 3.

Algorithme 3 Un GA de base.

1. **Génération aléatoire de la population initiale**
 2. **Calcul de la fonction sélective**
 3. **Répéter**
 - **Sélection**
 - **Croisement**
 - **Mutation**
 - **Evaluation de la fonction objective**
 4. **Jusqu'à** satisfaction d'un critère d'arrêt
-

Parmi les domaines d'application de cette heuristique, nous trouvons la segmentation d'images, où de nombreux travaux ont été réalisés [AT94, AT98, And99, KPK00].

Une approche très intéressante de segmentation d'images basée sur les MRFs est appelée "*selectionist relaxation*" [AT98, And99]. L'approche *selectionist relaxation* est proposée par Philippe Andrey et al. [AT98, And99] comme une méthode non supervisée de segmentation d'images basée sur les modèles Markoviens et les GAs. Dans cette approche, la transformation d'une image observée en une image résultat est obtenue par une population d'unités évoluant à travers un GA distribué (voir Figure 3.3).

Chaque unité est une association entre un vecteur candidat de caractéristiques et une étiquette. Cette dernière est utilisée pour désigner le pixel unité. Le vecteur de caractéristiques est utilisé dans le but de désigner une valeur objective 'fitness' de l'unité. La valeur objective 'fitness' de l'unité est mesurée par l'appariement entre le vecteur de caractéristiques et les données de la fenêtre de l'image sur quoi l'unité est centrée. Les caractéristiques que composent les vecteurs de l'unité sont arbitrairement choisies sur la base du type de segmentation. Par exemple, la matrice

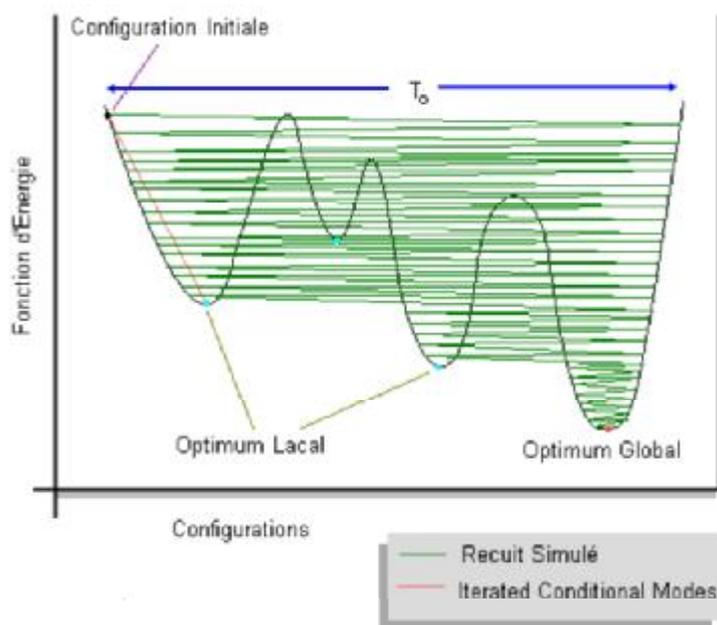


FIG. 3.1: Interprétation par un graphe de la convergence de l'ICM et du SA.

de pixels a été utilisée comme un vecteur de caractéristiques pour la segmentation à niveaux de gris. Par contre, dans la segmentation des images texturées, ces dernières peuvent être réalisées en utilisant un modèle de paramètre de texture comme des vecteurs caractéristiques.

La population de ces unités évolue itérativement à travers l'application des opérateurs génétiques. En effet, les unités dont les vecteurs de caractéristiques correspondent aux bons supports de l'image sont sélectionnées, recombinaées et mutées [AT98, And99]. Ces mécanismes génétiques permettent aux voisinages des bonnes unités de prendre la place de ceux non adéquats dans ces images (voir Figure 3.3).

Par ailleurs, Kim et al. [KPK00] ont présenté une méthode non-supervisée pour la segmentation d'images basée sur les MRFs en utilisant les GAs. Cette approche vise à réaliser une segmentation pour des séquences vidéos dégradées par du bruit.

Chaque "frame" dans une séquence est modélisé par un MRF, et la fonction

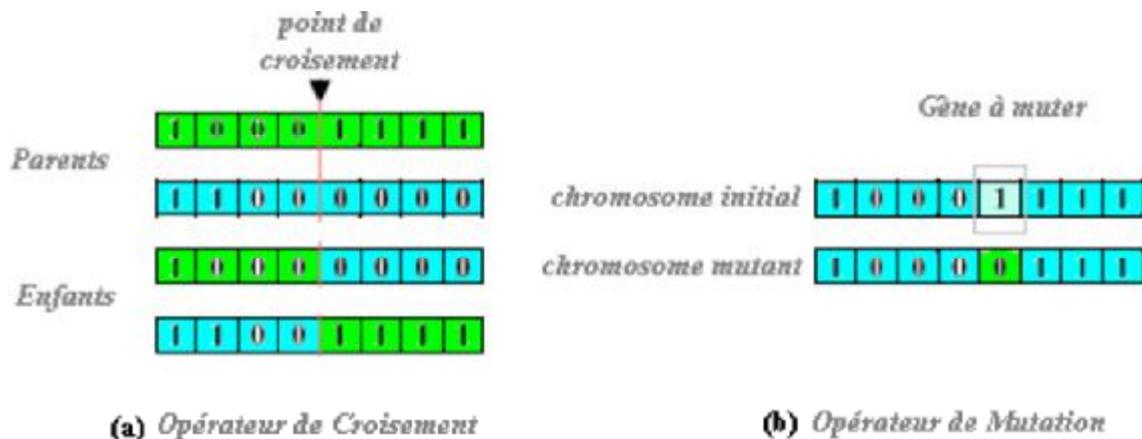


FIG. 3.2: Les opérateurs génétiques : (a) Croisement, (b) Mutation.

d'énergie pour chaque MRF est minimisée par des chromosomes qui évoluent en utilisant des algorithmes génétiques distribués intensivement parallèles. Cependant, cette méthode était encore entravée par la complexité du calcul informatique une fois appliquée à la segmentation de séquence. Pour améliorer l'efficacité informatique, seuls les chromosomes instables correspondant aux parties d'objets mobiles sont évolués [KPK00].

Dans sa thèse de Doctorat, Isabelle Quidu [Qui01] propose une approche de segmentation des images "SOund Navigation and Ranging" (SONAR) basée sur une optimisation par les GAs.

Une fonction d'énergie est optimisée par un algorithme génétique afin d'explorer une population d'individus caractérisés par leurs descripteurs de Fourier. Par transformation inverse, les descripteurs estimés sont associés au contour qui, de manière optimale, partage l'image sonar en deux régions permettant dans le même temps de classifier l'objet ciblé. En travaillant directement à partir des données sonar brutes, des étapes intermédiaires (segmentation et extraction d'attributs caractéristiques) interviennent dans le traitement séquentiel classiquement mis en œuvre pour la reconnaissance de formes. A travers les générations successives, l'ensemble des contours codés dans les chromosomes des individus évoluent suivant les lois de

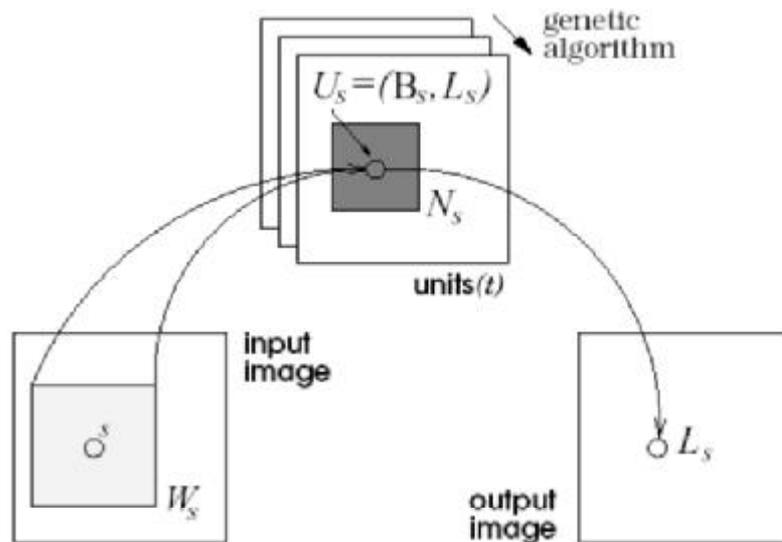


FIG. 3.3: Selectionist Relaxation. Les U_s désignent les unités, W_s les fenêtres d'entrée, L_s les étiquettes, N_s les voisinages et B_s désigne les vecteurs de caractéristiques.

la génétique selon un processus dynamique de classification de l'ombre [Qui01].

3.3.2 Segmentation d'images en utilisant les MASs

La notion des *Systèmes Multi-Agents* propose de distribuer l'expertise sur un groupe d'agents qui doivent être à même de travailler et agir dans un même environnement pour réaliser une tâche. Grâce au concept de compétition/coopération les agents travaillent ensemble dans le but d'arriver à un objectif final.

Les MASs ont été d'abord utilisés en système de vision par ordinateur par [LP94, LP93]. On retrouve d'autres travaux basés sur le concept MASs [RDG03, RRH99, Fer99, Flo98, BG88].

L'application présentée par Richard et al. [RDG03] concerne la partie qui traite des tâches de haut niveau dans le système de vision par ordinateur. Richard et al. [RDG03] ont défini une application dans l'interprétation des images du cerveau captées par résonance magnétique (en anglais "Magnetic Resonance Imaging brain scans interpretation").

L'approche proposée par Rares et al. [RRH99] utilisant les MASs dans les systèmes de vision par ordinateur est devenue très populaire.

Les MASs ont été étendus par la suite à la segmentation d'images [LT99,DMJ03,PSRa03,OB03].

L'utilisation du concept *agents* dans la plupart des approches de segmentation est basée essentiellement sur l'adaptation des traitements locaux aux comportements coopératifs (région/contour) des agents pour trouver les bonnes solutions [DMJ03,PSRa03].

En effet, dans les approches de Duchesnay et al. [DMJ03] et Porquet et al. [PSRa03], les agents correspondent aux régions d'une image. Ces agents ne sont pas chargés de construire les régions, car celles-ci existent déjà. Elles peuvent avoir été obtenues par une segmentation préliminaire choisie. Les agents sont alors chargés d'affiner cette segmentation par fusion ou division de régions, en tirant profit d'informations échangées avec leurs voisins.

L'approche de segmentation de Liu [LT99] utilise des agents autonomes, distribués aléatoirement dans l'image, à travers des processus incrémentaux de croisances de régions ou de contours. Partant d'un pixel (germe), un agent dans un processus incrémental de segmentation, est défini par son emplacement dans l'image, un ensemble de paramètres caractéristiques et par un ensemble de règles fixant son évolution.

Dans une autre approche, Ouadfel et Batouche [OB03] utilisent les systèmes fournis "Ant Colony Optimization or Ant System" [CDM⁺96,MD96] comme un outil de modélisation pour concevoir un algorithme de segmentation d'images, basée sur les MRFs, appelé ACS-MRF. Dans cette approche, une colonie de fourmis artificielles recherche une solution globalement optimale selon la méthode d'estimation MAP.

En fait, l'ACS-MRF est une approche distribuée basée sur une population des fourmis considérées comme des agents réactifs. Chaque agent (fourmi) construit un ensemble de solutions possibles en utilisant l'information du phéromone accumulée

par les autres fournis dans une matrice commune appelée matrice de phéromone. Après un certain nombre d'itérations, la meilleure partition représentant la valeur optimale d'une fonction d'énergie MAP est déterminée. Un algorithme de recherche locale simple est utilisé dans le but d'améliorer la qualité de la solution trouvée par une des fournies en rendant la convergence de l'algorithme plus rapide.

Une autre approche de segmentation basée sur les MASs a été proposée l'année passée par Bovenkamp, Dijkstra et al. [BDBR04]. Ce MAS a été appliqué pour l'interprétation des images "IntraVascular UltraSound". Les agents permettent l'adaptation dynamique des algorithmes de segmentation basés sur la connaissance des contraintes globales, la connaissance contextuelle, l'information locale d'image et l'estimation personnelle. D'une façon générale le contrôle d'agent permet aux algorithmes de segmentation d'être plus simples et d'être appliqués à un éventail de problèmes avec une fiabilité plus élevée.

Dans leur travail, Veenman, Reinders, et Backer [VRB03] ont proposé un modèle pour le problème de classification (clustering) qui n'a pas besoin de la connaissance a priori au sujet du nombre de classes, en utilisant la variation minimale d'intra-classe [VRB03]. En plus, au lieu de maximiser la variation d'inter-classe, ils imposent une contrainte dure à la variabilité d'intra-classe pour l'union de deux classes. Les auteurs estiment qu'une telle contrainte est inévitable, dans la recherche de solutions utiles au problème de classes. Considéré comme un résultat, le modèle proposé permet la classification des données en un nombre inconnu a-priori de classes. En plus, pour la segmentation, il est spécialisé et propose l'approche connue sous l'appellation anglaise "cellular coevolutionary algorithm" afin d'optimiser le modèle de segmentation d'images d'une manière parallèle distribuée.

Les auteurs appliquent ce modèle en utilisant les approches de segmentation basée sur les MRFs et les méthodes division-fusion.

L'approche proposée souffre de quelques insuffisances [VRB03], d'une part dans la segmentation des images de séquence, d'autre part, au niveau de l'initialisation. En effet, l'approche utilise un MAS où chaque agent optimise localement sur la base d'un critère donné.

Sziranyi et al. [SZC⁺00] ont prouvé que des modèles MRFs peuvent être mis en application en utilisant des fonctions simples de VLSI et une architecture cellulaire parallèle connue sous le nom anglais de "Fully Parallel Cellular Network Architectures". Dans ce projet, ils proposent des solutions parallèles aux algorithmes de relaxation pseudo-stochastiques de segmentation.

3.4 Conclusion

Dans ce chapitre, nous avons présenté un préambule sur des méthodes de segmentation d'images basée sur les MRFs.

Nous nous sommes intéressés, essentiellement, aux approches utilisant la théorie de la décision au sens Bayésien qui est la base de l'estimation MAP.

Nous avons introduit par la suite les deux algorithmes d'optimisations les plus appliqués en segmentation d'images basée sur les MRFs, qui sont le SA et l'ICM. Après avoir présenté ces deux approches d'optimisations stochastique et déterministe, nous avons consacré la section suivante aux différentes approches d'analyse et de segmentation d'images basée sur les GAs et celle basée sur les MASs comme outils de modélisation.

Ces approches de segmentation d'images basée sur les MRFs souffrent de plusieurs insuffisances. Pour les approches déterministes (par exemple l'ICM), les processus de segmentations dépendent fortement de l'initialisation et convergent vers des optima locaux.

De même, l'approche SA et les approches à base de fonction d'équilibre peuvent facilement buter sur un optimum local car le contrôle du changement de la température reste très difficile à réaliser en pratique. Un autre inconvénient majeur réside dans le fait que ce type d'approches basées sur la simulation du recuit nécessite un temps de calcul considérable.

Enfin, les approches de segmentation d'images basée sur des GAs classiques né-

cessitent un nombre considérable d'individus ainsi qu'un très grand nombre d'itérations pour converger.

Les chapitres suivants sont destinés principalement à proposer des solutions afin de pallier aux insuffisances des approches classiques.

CHAPITRE 4

UNE APPROCHE DE SEGMENTATION D'IMAGES BASÉE SUR LES MRFS ET LE MODÈLE DE BAK-SNEPPEN

Nous combinons le modèle de Bak-Sneppen et les MRFs pour définir une approche de segmentation d'images. Les pixels de l'image sont considérés comme des espèces, l'image est prise comme le système-grille de Bak-Sneppen. L'adaptabilité de ces espèces est mesurée en utilisant la probabilité a posteriori. A chaque temps discret, certaines de ces espèces non adaptées sont choisies pour un changement aléatoire dans leurs états modifiant ainsi leurs valeurs d'adaptabilité. Chaque modification d'une espèce engendre un changement dans ces espèces voisines. Grâce à ses simples modifications des réactions en chaîne appelées avalanches se propagent dans le système entier créant ainsi une dynamique. Ceci permet aux parties du système de s'autoréorganiser dans des catégories. En effet, après un nombre adéquat d'itérations, le système converge vers un état de haute corrélation appelé SOC. Dans cet état, toutes les espèces ont une bonne valeur d'adaptabilité.

4.1 Introduction

On peut considérer la technique de segmentation d'images [HS85] comme un problème d'estimation d'un processus étiquettes à partir d'une réalisation pixels modélisé par les MRFs [GG84, Bes86, DE87, DJNC90, KZB92]. Les deux algorithmes les plus connus dans ce domaine sont le SA [GG84] et l'ICM [Bes86].

Dans le SA, la convergence vers l'optimum global est prouvée théoriquement dans le travail de Stuart et Donald Geman [GG84]. Cependant, le problème d'ajustement des paramètres relatifs à la simulation réduit d'une manière considérable l'efficacité de cette heuristique.

En effet, le SA combine la distribution de Gibbs et une fonction de refroidissement. Ce type de modélisation est issu de la simulation d'un comportement d'équilibre d'un grand système bâti sous forme d'une structure de grille. Dans ce type d'approche le contrôle du changement de la température est d'une grande importance. Le cas du programme qui simule le recuit est très difficile à mettre en œuvre. Le processus peut facilement buter sur un optimum local. Un autre inconvénient majeur est que le SA reste un algorithme qui nécessite un temps de calcul considérable, surtout en segmentation d'images.

L'ICM [Bes86] est proposé comme une méthode alternative de la segmentation d'images basée sur les MRFs. A partir d'une configuration sous optimale, l'ICM maximise la probabilité du champ de segmentation par un processus déterministe et itératif modifiant ainsi les classifications des pixels. L'ICM est un algorithme qui accomplit sa tâche dans un temps de calcul très court. Cependant, sa convergence dépend de l'image initiale classifiée par laquelle il commence le processus de segmentation.

D'autres méthodes de segmentation combinant les MRFs et les GAs [Hol75, Gol89] sont présentées dans les travaux [AT94, AT98, KPK00].

Dans ce chapitre, nous proposons une nouvelle approche de segmentation d'images. C'est une méthode hybride combinant le modèle de Bak-Sneppen et les MRFs. Les niveaux de gris d'une image sont vus comme des espèces situées sur les nœuds d'une

grille du modèle de Bak-Sneppen [BTW87, BS93].

En réalité, nous utilisons l'heuristique *optimisation extrême* "Extremal Optimization (EO)" [Boe99, BP01, BP03, Boe03] inspirée du mécanisme de Bak-Sneppen. Nous appelons notre approche, l'algorithme MRF-EO ("Markov Random Fields and Extremal Optimization") pour la segmentation d'images.

Nous considérons un système-grille où chaque nœud correspond à une espèce (pixel, site étiquette, texture, etc...). Nous associons à chaque espèce s sa probabilité a posteriori λ_s qui représente la valeur objective locale de cette espèce. A cet effet, nous adoptons le critère MAP.

Dans ce type de processus, l'évolution du système est basée simplement sur la sélection des espèces non adaptées (site étiquettes) afin de modifier leurs états (classes).

En effet, à chaque cycle d'évolution, le système sélectionne un ensemble de sites étiquettes non adaptées pour modification de leurs valeurs objectives (d'adaptabilité).

Le changement de la valeur objective d'une espèce (site étiquette) engendre un changement dans les valeurs objectives des espèces voisines. Après un certain nombre d'itérations, le système converge vers un état de haute corrélation appelé *Self-Organized Criticality* (SOC).

Dans cet état, les espèces se réorganisent dans des catégories où chacune représente une région (classe) de l'image.

Il est à noter que l'état SOC est un état non stable et des fluctuations issues d'interactions entre espèces voisines connues sous le nom d'*avalanches* peuvent se produire. Ces réactions en chaîne se propagent dans le système permettant ainsi au processus d'accéder à de nouvelles configurations dans l'espace de solutions. Ces avalanches dues à de petites perturbations peuvent changer la configuration entière du système.

Nous décrivons notre approche en deux phases principales :

La phase d'initialisation crée une *configuration initiale* x .

La phase de mise à jour modifie la *configuration courante*. Après évaluation des

valeurs objectives de ses sites étiquettes un changement aléatoire d'un ensemble de sites étiquettes est opéré.

4.2 Notations, Définitions et Modèles

Ce paragraphe décrit brièvement le modèle Markovien adopté dans cette approche.

4.2.1 Quelques définitions de base

Les pixels de l'image sont indexés par un système-grille rectangulaire $S = \{1, \dots, t, \dots, MN\}$ où chaque pixel représente le niveau de gris associé aux noeuds (sites) de la maille (grille) à MN -sites ($MN = M \times N$), où t est un site.

L'image idéale et celle observée sont représentées, respectivement, par les vecteurs aléatoires suivants :

$$X = (X_1, \dots, X_t, \dots, X_{MN}), \quad X_t \in \{1, \dots, C\}, \quad C \text{ désigne le nombre de catégories et } Y = (Y_1, \dots, Y_t, \dots, Y_{MN}), \quad Y_t \in \{0, \dots, 255\}.$$

Nous supposons que Y est une image idéale bruitée additivement par un bruit gaussien [DJNC90, LD89].

4.2.2 Système de voisinage adopté

Nous présentons ici notre système de voisinage qui sera utilisé dans cette approche.

Un système de voisinage $NS = (V_i \subset S, i \in S)$ est une collection de sous-ensembles V_i de S vérifiant les conditions suivantes :

(1) $i \notin V_i$ et **(2)** $j \in V_i \Leftrightarrow i \in V_j$.

Une clique c est un ensemble de points mutuellement voisins. On peut écrire :

$$\forall r, t \in c, r \in V_t.$$

Pour un système de voisinage de premier ordre, le voisinage du site correspond aux quatre sites les plus proches (haut, bas, gauche et droite).

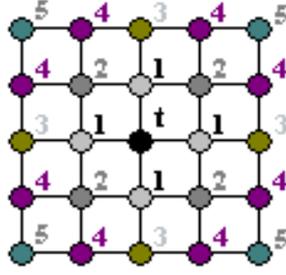


FIG. 4.1: Système de voisinage pour Gibbs/MRF.

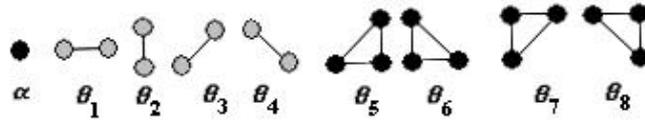


FIG. 4.2: Structure de la clique pour un système de voisinage second-ordre.

Le numéro d'ordre du voisinage jusqu'à l'ordre cinq est illustré dans la Figure 4.1. La structure de la clique pour un MRF second-ordre est illustrée dans la Figure 4.2.

Soit X un MRF respectant un système de voisinage NS si :

1. Pour tout $x \in \Omega$: $P(X = x) > 0$. où Ω l'ensemble des configurations possibles.
2. $\forall t \in S, x \in \Omega$: $P(x_t/x_j, j \in S - \{t\}) = P(x_t/x_j, j \in V_t)$

Soit X un MRF adoptant un système de voisinage NS si et seulement si $P(X = x)$ suit la loi de Gibbs définie par : $P(X = x) = e^{-U(x)}/Z$ où $Z = \sum_{x \in \Omega} e^{-U(x)}$ est la fonction de partition, $U(x)$ est la fonction d'énergie :

$$U(x) = \sum_{t=1}^{MN} \sum_{r \in V_t} \theta_r \delta(x_t, x_r) \quad (4.1)$$

θ_r sont les paramètres associés aux cliques et $\delta(a, b) = -1$ si $a = b$, 1 sinon.

$P(X = x)$ est appelée la probabilité a-priori.

L'objectif est de trouver x^* qui maximise la probabilité a-posteriori $P(x/y)$.
C'est à dire :

$$x^* = \arg \max_{x \in \Omega} P(x/y) \quad (4.2)$$

D'après le théorème de Bayès nous avons :

$$P(x/y) = \frac{P(y/x)P(x)}{P(y)} \quad (4.3)$$

où $P(x)$ est la densité a-priori de x et $P(y/x)$ représente la probabilité conditionnelle de y . On remarque que la densité a-priori de y , $P(y)$ ne dépend pas de x , alors on peut écrire :

$$x^* = \arg \max_{x \in \Omega} P(y/x)P(x) \quad (4.4)$$

Pour chaque site s on écrit :

$$P(y_s/x_s) = \frac{1}{\sqrt{2\pi\sigma_{x_s}^2}} \cdot e^{-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2}} \quad (4.5)$$

où μ_{x_s} et $\sigma_{x_s}^2$ sont la moyenne et la variance du bruit Gaussien.

Puisque les y_s sont indépendants, la probabilité conditionnelle prend la forme suivante :

$$P(y/x) = \prod_{s \in S} P(y_s/x_s) \quad (4.6)$$

En développant cette formule on obtient :

$$P(y/x) = \prod_{s \in S} \frac{1}{\sqrt{2\Pi}} \cdot e^{-\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} - \log(\sigma_{x_s})} \quad (4.7)$$

La probabilité $P(x/y)$ suit la distribution de Gibbs donnée par : $P(x/y) = e^{-U(x/y)}/Z_y$ où Z_y est la constante de normalisation, $U(x/y)$ la fonction d'énergie donnée par l'équation suivante :

$$U(x/y) = \sum_{t=1}^{MN} [\ln(\sqrt{2\Pi}\sigma_{x_t}) + \frac{(y_t - \mu_{x_t})^2}{2\sigma_{x_t}^2} + \sum_{r \in V_t} (\beta\delta(x_t, x_r))] \quad (4.8)$$

β est un paramètre positif du modèle contrôlant l'homogénéité des régions de l'image.

Maintenant, nous pouvons définir la segmentation d'images par un processus d'estimation d'une configuration x minimisant une fonction d'énergie $U(x/y)$. Nous appliquons en fait, la méthode d'estimation MAP [DJNC90].

4.2.3 Le modèle de Bak-Sneppen et l'heuristique optimisation extrême

Le terme SOC est associé à une nouvelle *approche* initialement développée par Per Bak [Bak96] comme une étude du comportement complexe émergeant dans les systèmes physiques et biologiques.

Le modèle d'évolution de Bak-Sneppen est une application réussie du concept SOC [Bak96].

Dans le modèle de Bak-Sneppen [BS93], ℓ espèces sont situées sur un cercle

où chacune a sa propre valeur d'adaptation indépendante, uniformément distribuée sur $[0, 1]$. A chaque cycle, le système est mis à jour par localisation de l'espèce non adaptée correspondant à la plus petite valeur d'adaptation "fitness" ainsi qu'à ses deux voisins. Ces trois espèces ont leurs valeurs d'adaptation remplacées par d'autres valeurs dans $[0, 1]$. Ensuite, chaque espèce est représentée par une seule valeur mesurant de ce fait son pouvoir d'adaptation à son environnement. Après un nombre suffisant d'itérations, le système atteint un état meilleur appelé SOC [Bak96, BTW87], dans lequel la majeure partie des espèces ont des valeurs d'aptitude plus grandes qu'un seuil donné (voir Figure 4.3.(a)).

Dans notre cas, les espèces sont placées sur des sites (positions) d'un système-maille (voir Figure 4.3.(b)), dans lequel chaque espèce possède une valeur objective sur l'intervalle $[0, 1]$ décrivant son degré d'aptitude. Dans ce modèle, plus la valeur objective est élevée plus grande est la chance de survie pour l'espèce [BS93].

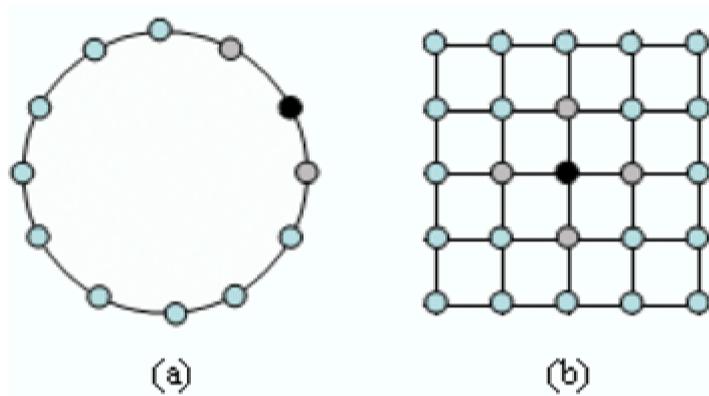


FIG. 4.3: Le modèle de Bak-Sneppen : (a) Cercle, (b) Maille.

A chaque cycle d'évolution, l'espèce la moins adaptée correspondant à la plus petite valeur objective est choisie pour un changement aléatoire. La modification de la valeur objective de cette espèce engendre des changements des valeurs objectives des espèces voisines.

Après un certain nombre d'itérations, le système atteint un état approprié appelé SOC [Bak96, BTW87].

Dans cet état, la majeure partie de ces espèces ont des valeurs objectives (fitness values) de bonne qualité.

Ce mécanisme de Bak-Sneppen a été exprimé dans une méta-heuristique appelée optimisation extrême par Stephan Boettcher et al. [Boe99, BP00, BP03, Boe03]. Ils en ont développé deux versions :

l'optimisation extrême de base [Boe99] et le τ -optimisation extrême [BP00, BP03, Boe03].

Dans la seconde version τ -optimisation extrême, le processus est basé sur la sélection d'un ensemble de variables (espèces) afin d'en modifier les états. Toutes les espèces du système sont exposées au changement d'état (disparition) sans discrimination [Boe99, BP00, BP01, BP03, Boe03]. Ce principe est la principale amélioration de la première version de l'heuristique. Cette amélioration offre un aspect stochastique à l'heuristique et la place parmi les méthodes de recherches locales puissantes "local-search".

4.3 L'approche MRF-EO pour la segmentation d'images

Dans ce travail, nous modélisons la segmentation d'images par une combinaison des MRFs et le modèle de Bak-Sneppen. L'introduction du nouveau paradigme SOC dans le domaine de la segmentation est d'une grande importance grâce aux avantages qu'il offre dans le domaine de l'optimisation combinatoire des systèmes à larges mailles (des problèmes NP-complet).

En effet, on considère les sites étiquettes x_i comme des espèces évaluées par la fonction objective locale donnée par la probabilité a-posteriori λ_i (voir Equation 4.9) et l'image représentée par la structure maille comme le système-maille du modèle de Bak-Sneppen.

$$\lambda_i = P(x_i/x_j, j \in V_i) \quad (4.9)$$

Dans les sections suivantes nous présentons en détail notre approche que nous avons appelée MRF-EO pour la segmentation d'images qui s'appuie, essentiellement, sur l'application de la méta-heuristique τ -optimisation extrême.

L'algorithme MRF-EO pour la segmentation d'images est divisé en deux phases principales : la phase d'initialisation et la phase de mise à jour.

Dans la première, le processus crée une configuration initiale $x^{(0)}$. Il est préférable que cette configuration initiale soit sous optimale pour accélérer le processus de la segmentation.

La deuxième phase est itérative, elle met à jour la configuration courante. Cette modification de la configuration courante est basée sur une simple sélection aléatoire pour le changement d'un ensemble de *sites étiquettes* jugées inadéquates. En effet, à chaque temps discret d'exécution (temps d'évolution du système), les sites étiquettes non adaptées (sélectionnées en utilisant la fonction objective) auront de nouvelles étiquettes.

Par ailleurs, un seul site modifié dans sa valeur d'étiquette va engendrer des changements dans les valeurs objectives des sites voisins.

Ces réactions en chaîne appelées *avalanches* qui se propagent dans le système entier sont obtenues grâce à une simple modification. Après un certain nombre d'itérations, les sites étiquettes se réorganisent dans des catégories, où chacune représente une région de l'image segmentée.

Cet état général que prend le système est appelé état SOC.

4.3.1 La phase d'initialisation

Cette phase de l'algorithme MRF-EO est la création d'une configuration initiale $x^{(0)}$ représentant le point de départ de notre processus. Cette solution initiale est créée à partir d'une image observée y de taille MN . Dans cette procédure nous utilisons l'algorithme K-moyennes.

Après la création de cette configuration initiale, le processus évalue les sites

étiquettes $x_t^{(0)}$ en utilisant la fonction λ_i (voir Equation 4.9), puis on calcule $U = U(x^{(0)}/y)$.

4.3.2 La phase de mise à jour

4.3.2.1 La sélection des mauvais sites étiquettes

A chaque itération de l'évolution du système, le processus détermine un nombre fini de sites étiquettes inadéquates par ordre décroissant selon leurs valeurs objectives, la plus petite étant classée au premier rang et ainsi de suite. Ceci revient à trouver une permutation π des sites étiquettes $x_t : \lambda_{\pi(1)} \leq \dots \leq \lambda_{\pi(MN)}$ et modifier un ensemble de sites étiquettes selon la règle suivante : Plus le rang est élevé, plus grandes sont ses chances de survie.

En fait, le processus choisit un nombre de variables faibles selon la loi de puissance $p_s \propto s^{-\tau}$ où s est le rang du site étiquette et τ l'unique paramètre de sélection.

Une remarque importante est que tous les sites étiquettes font l'objet d'une modification sans discrimination, ce qui permet au processus d'accéder à toutes les configurations possibles [Boe99, BP00, BP01, BP03]. Cet aspect stochastique important offre plus d'efficacité au processus de recherche.

Pour calculer p_s , nous utilisons la formule suivante [Boe03] :

$$p_s = (\tau - 1) \times (s^\tau) / ((M * N)^{\tau-1} - 1)$$

4.3.2.2 L'activité de co-évolution du système

Si la valeur objective "fitness" d'une espèce (individu, variable) dépend d'autres espèces de son voisinage, alors on dit qu'il y a co-évolution dans le système. En effet, le changement d'une espèce peut engendrer le changement du paysage entier de la structure du système [Sch02](voir Figure 4.4).

Dans notre approche MRF-EO, l'activité de co-évolution du système n'est pas imposée de l'extérieur ni par un phénomène d'équilibre.

Site i	$i = 1$	$i = 2$	$i = 3$	$i = 4$	$i = 5$	$i = 6$
Site étiquette x_i	x_1	x_2	x_3	x_4	x_5	x_6
Valeur de λ_i	0,53	0,1	0,35	0,63	0,8	0,25
$\pi(i)$	2	6	3	1	4	5
P_i	0,5	0,27	0,13	0,05	0,03	0,02
$\mu(i)$	0,38	0,25	0,15	0,025	0,5	0,8

TAB. 4.1: Sélection et modification de sites étiquettes $\pi(1)$, $\pi(2)$ et $\pi(4)$.

Grâce au mécanisme de Bak-Sneppen, l'approche MRF-EO opère sans un nombre gênant de paramètres.

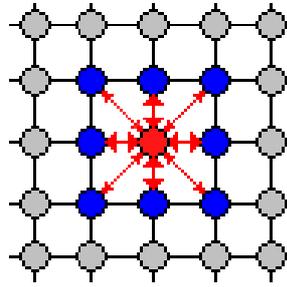


FIG. 4.4: Interactions entre les sites étiquettes sur une fenêtre 3×3 .

La figure 4.4, montre que la modification d'un seul site étiquette peut changer complètement les valeurs objectives des sites voisins (tout le paysage voisin change). Cette activité co-évolutionnaire de l'approche MRF-EO mène à des réactions en chaîne qui sont une des clés appropriées aux méthodes d'optimisation des systèmes fortement désordonnés. On peut présenter l'approche MRF-EO par l'algorithme 4.

4.4 Résultats expérimentaux

Dans ce travail, nous avons adopté le modèle d'Ising qui est un modèle possédant deux propriétés : l'*Homogénéité* et l'*Isotropie* (voir [GG84]) :

1. *Homogénéité* : c'est à dire strictement stationnaire.
2. *Isotropie* : c'est un modèle invariant par rotation.

Dans cette section, nous présentons quelques résultats expérimentaux de notre approche, puis les comparons avec l'algorithme ICM. L'évaluation est faite sur un

Algorithme 4 Les étapes du MRF-EO.

- 1) Créer une première solution $x^{(0)}$ de N classé à partir de y $M \times N$:
Le MRF-EO crée une première configuration sous-optimale à partir de l'image observée en utilisant K-moyennes.
Pour $t \in \{1, \dots, MN\}$ Calculer λ_t . Calculer $U = U(x/y)$. Poser $x_{best} = x$, $F_{best} = U$ et itération = 1.
 - 2) Trouver une permutation π des sites étiquettes x_t :
 $\lambda_{\pi(1)} \leq \dots \leq \lambda_{\pi(MN)}$.
Exemple : Dans la table 4.1, nous supposons que $N_1 = 2$ et $M_1 = 3$. On a x_2 est le plus mauvais site étiquette, x_5 le meilleur site étiquette.
 - 3) Pour $s = 1..MN$
 - Calculer la probabilité $P_s \propto s^{-\tau}$ où τ est un paramètre.
 - Générer un nombre aléatoire uniforme μ_s dans $[0, 1]$.
 - Si $\mu_s \leq P_s$ Alors modifier l'étiquette du site $\pi(s)$.*Exemple* : Dans la table 4.1, le MRF-EO remplace les étiquettes des sites $\pi(1)$, $\pi(2)$ et $\pi(4)$.
 - 4) Pour $t = 1..MN$ évaluer λ_t de x .
Calculer $U = U(x/y)$.
 - 5) Si $U < F_{best}$ puis $x_{best} = x$ et $F_{best} = U$.
 - 6) itération=itération+1.
 - 7) Si itération \leq un nombre donné Alors goto 2.
 - 8) Sortir x_{best} et F_{best} .
-

ordinateur personnel PC pentium 4 de vitesse d'horloge 2.66 GHZ et de capacité mémoire 256 MB.

Le modèle spatial que nous avons adopté est un modèle d'Ising second-ordre.

Ce modèle utilise seulement les cliques n'ayant pas plus de deux noeuds et non-zéro potentiel. Puisque nous utilisons un modèle second-ordre, le nombre de cliques employées est de quatre, d'où dans l'équation 4.1, $\theta_1 = \theta_2 = \theta_3 = \theta_4 = \beta$, elles sont présentées en gris (voir Figure 4.2).

Nous avons pris une seule valeur du paramètre $\beta = 1.5$ maintenue constante tout au long de chaque processus de segmentation. La segmentation est évaluée

en utilisant deux critères qui sont : l'évaluation visuelle et l'évaluation à partir des valeurs de la fonction objective (fonction d'énergie). L'image observée y est celle représentée initialement pour tous les algorithmes donnés par l'estimation du maximum vraisemblance de la segmentation.

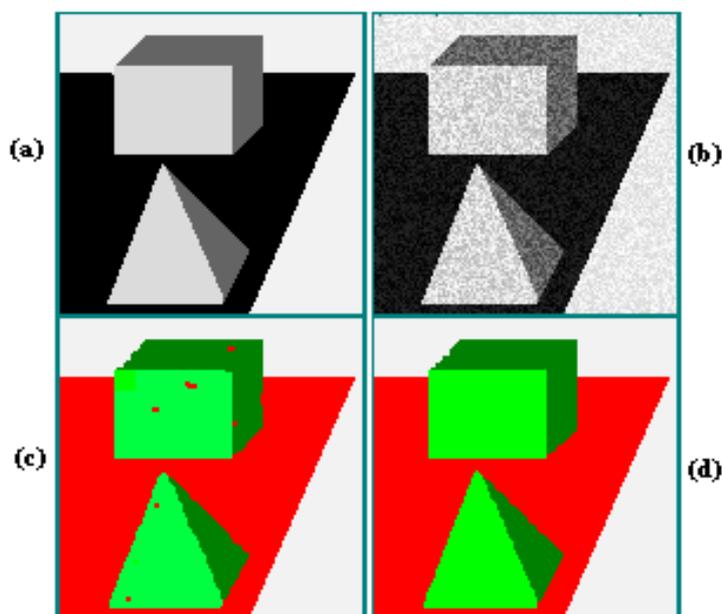


FIG. 4.5: Segmentation d'une image synthétique bruitée, (a) Image idéale, (b) Image bruitée, (c) Image segmentée par ICM, (d) Image segmentée par MRF-EO. Paramètres : $\beta = 1.5$, $\tau = 1.4$, $C = 4$.

Dans les Figures 4.5 et 4.6, nous présentons la segmentation de deux scènes bruitées qui contient un cube et une pyramide. Les résultats obtenus par notre approche MRF-EO sont largement meilleurs, malgré les interférences et la minceur de certaines régions et objets, tandis que l'ICM ne parvient vraiment pas à extraire les détails des objets.

La figure 4.7 montre que l'image de la pièce mécanique est mieux segmentée en utilisant notre approche MRF-EO que par l'ICM. On voit clairement qu'au niveau de la denture d'ICM, les détails sur l'image observée sont mal détectés. En revanche, notre algorithme MRF-EO atténue le bruit du niveau de la denture de la pièce de façon appréciable .

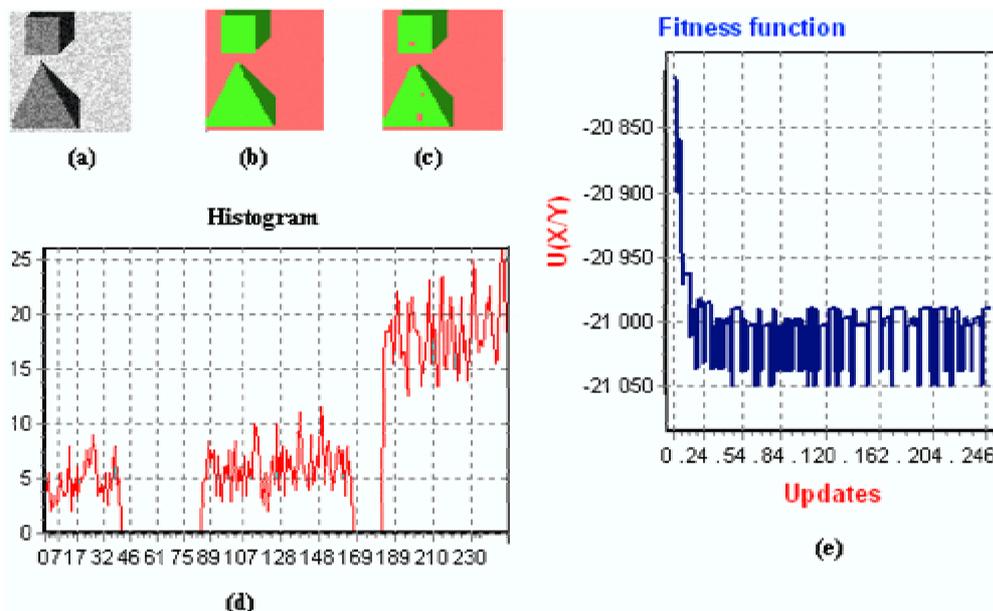


FIG. 4.6: Segmentation d'une image bruitée (64×64), (a) Image observée, (b) Image segmentée par MRF-EO, (c) Image segmentée par ICM, (d) Histogramme de (a). (e) Graphe d'évolution de MRF-EO. Paramètres : $\beta = 1.5$, $\tau = 2.2$, $C = 3$.

La figure 4.8 présente une analyse de l'évolution de la fonction objective pour la segmentation de la pièce mécanique. Nous constatons que l'algorithme converge bien vers le point optimal et reste toujours actif dans la recherche de nouvelles solutions. En effet, il franchit les barrières jusqu'aux temps limites d'exécution pour explorer de nouvelles segmentations. Cette activité est due aux fluctuations résultantes du caractère co-évolutionnaire de l'approche.

Dans la Figure 4.11, notre approche est appliquée à une scène réelle représentée par une vue d'un bâtiment. Le résultat de notre MRF-EO est nettement meilleur que celui de l'ICM. Nous le constatons au niveau des potelets à droite.

Les avalanches jouent un rôle important dans la recherche locale, comme on le voit dans la figure 4.8. Ces fluctuations sont largement similaires dans les travaux d'applications réalisées par l'heuristique optimisation extrême [BP01, MB02b, Boe03].

Dans notre approche, la meilleure valeur du τ , est dans l'intervalle [1.3, 2.25].

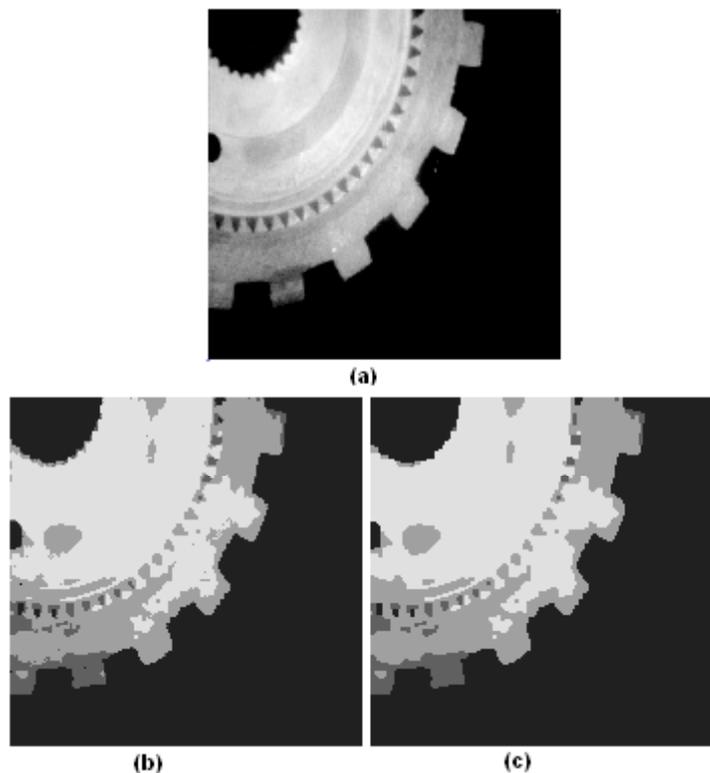


FIG. 4.7: Exemple d'une segmentation d'une pièce mécanique, (a) Image observée, (b) Image segmentée par MRF-EO, (c) Image segmentée par ICM. Paramètres : $\beta = 1.5$, $\tau = 1.4$, $C = 4$.

Elle est estimée après différentes exécutions de l'algorithme MRF-EO pour la même image observée et pour la même durée (voir Figure 4.10).

4.5 Conclusion

Dans ce chapitre, nous avons introduit une nouvelle approche de segmentation d'images basée sur les MRFs. Cette approche combine les modèles de Markov et de Bak-Sneppen. En effet, les sites étiquettes sont considérés comme des espèces dont les valeurs objectives sont évaluées par la probabilité a-posteriori, et l'image est considérée comme un large système-maille de Bak-Sneppen dont les états SOC présentent les estimations MAP.

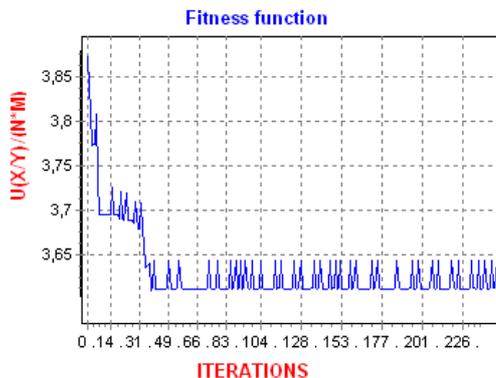


FIG. 4.8: Evolution de la fonction objective dans la segmentation MRF-EO de la pièce.

En effet, Bak-Sneppen comme modèle SOC intégré dans un modèle spatial Markovien peut amplifier encore plus l'activité du processus de segmentation d'images.

A la différence de l'ICM, l'aspect stochastique dans le MRF-EO est préservé et le processus peut démarrer d'une configuration quelconque.

L'avantage de notre approche par rapport au SA, est qu'elle n'a besoin que d'un petit nombre de paramètres et ne s'appuie pas sur un phénomène d'équilibre (cas des approches basées sur l'heuristique SA).

Notre approche n'a pas de paramètre de contrôle et les états optimaux émergent spontanément sans aucune intervention extérieure.

La mise à jour de quelques sites étiquettes dans une configuration provoque des interactions locales entre les entités de bas-niveau du système.

La robustesse de l'approche proposée est due aux larges fluctuations appelées avalanches venant de la modification de quelques mauvais sites étiquettes. Cette activité co-évolutionnaire du système permet au processus d'accéder à de nouvelles solutions à n'importe quelle phase d'exécution.

Cependant, l'inconvénient de cette approche MRF-EO est au niveau de la complexité. En effet, l'approche MRF-EO est une méthode d'optimisation stochastique d'une fonction à $M \times N$ variables où ce nombre est très grand. Et comme MRF-EO est basée sur une étape de tri, elle devient une approche très coûteuse en matière

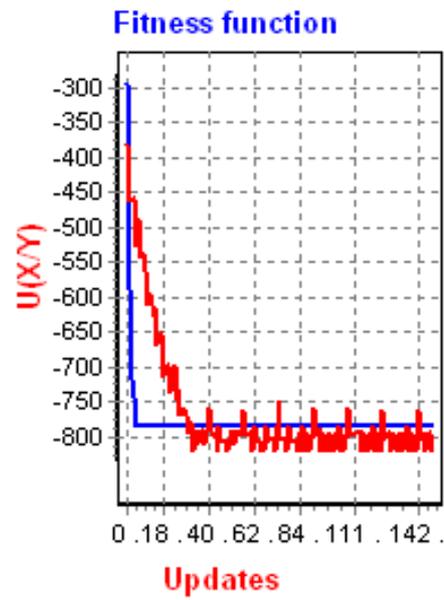


FIG. 4.9: Comparaison des fonctions objectives de l'ICM (bleu) et MRF-EO (rouge) pour une segmentation.

de temps de calcul.

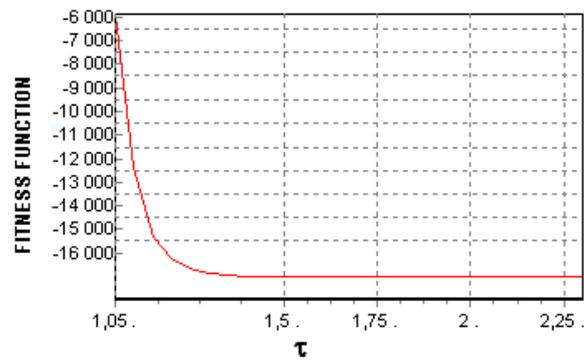


FIG. 4.10: Estimation de τ avec différentes exécutions de l'algorithme MRF-EO (pour une même durée).

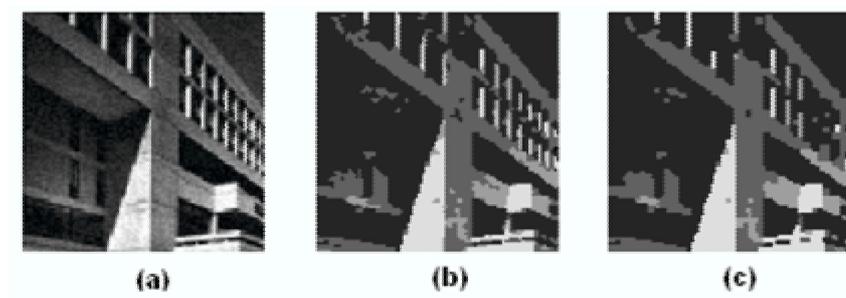


FIG. 4.11: Segmentation d'une scène réelle. (a) bâtiment (b) image segmentée par MRF-EO (c) image segmentée par ICM.

CHAPITRE 5

UNE APPROCHE ÉVOLUTIONNAIRE DISTRIBUÉE MAS-GA POUR LA SEGMENTATION BASÉE SUR LES MRFS

Nous avons proposé dans le chapitre précédent une méthode d'optimisation stochastique d'une fonction à $M \times N$ variables. Comme l'approche MRF-EO s'appuie sur une procédure de tri, elle devient très coûteuse en matière de temps de calcul. Dans ce chapitre, nous proposons une approche évolutionnaire distribuée pour la segmentation d'images basée sur les MRFS. Nous utilisons les MASs, les GAs et l'ICM pour définir cette approche.

5.1 Introduction

Dans ce chapitre, nous présentons une nouvelle approche évolutionnaire distribuée pour la segmentation d'images basée sur les MRFs. Cette approche est réalisée en utilisant une architecture MAS.

Comme évoqué précédemment, la convergence du SA vers l'optimum global est démontrée théoriquement dans le papier de Stuart et Donald Geman [GG84]. Cependant, le problème d'ajustement des paramètres relatifs à la simulation réduit d'une manière considérable la robustesse de cette heuristique.

En effet, le SA combine la distribution de Gibbs et une fonction de refroidissement. Dans ce type d'approche, le contrôle du changement de température est d'une grande importance. Le SA reste un algorithme coûteux en temps de calcul, surtout dans son application en segmentation d'images.

Nous avons proposé dans le chapitre précédent l'approche MRF-EO pour la segmentation d'images basée sur les modèles MRF et Bak-Sneppen. Elle n'a pas de paramètre de contrôle et les états optimaux émergent spontanément sans aucune intervention extérieure. La mise à jour de quelques sites étiquettes dans une configuration provoque des interactions locales entre les entités de bas-niveau du système. Cette activité co-évolutionnaire permet au processus d'accéder à de nouvelles solutions à n'importe quelle phase d'exécution. Cependant, l'approche MRF-EO est une méthode d'optimisation stochastique d'une fonction à $M \times N$ variables. Comme l'approche MRF-EO s'appuie sur une procédure de tri, elle devient très coûteuse en matière de temps de calcul.

A partir d'une configuration sous-optimale, l'ICM maximise la probabilité du champ de segmentation par un processus déterministe et itératif changeant ainsi les classifications des pixels. L'ICM est un algorithme qui accomplit sa tâche dans un temps de calcul très court. Cependant, il reste toujours dépendant de la phase

initialisation et converge vers un optimum local.

Les GAs sont aussi utilisés en segmentation d'images [And99, MBP94, BL94, CDPY99, LD89]. Ces approches nécessitent un grand nombre d'individus dans la population ainsi qu'un nombre important d'itérations pour converger.

Par ailleurs, Duchesnay et al. [DMJ03], Porquet et al. [PSRa03] ont proposé deux applications de segmentation d'images basées essentiellement sur l'adaptation des traitements locaux aux comportements coopératifs d'un ensemble d'agents pour accéder les bonnes segmentations. Richard et al. [RDG03], Rares et al. [RRH99] ont défini, également deux applications MASs pour le traitement d'images. Ces approches sont toutes des applications distribuées composées d'entités, modules indépendants appelés *agents*, ou parfois utilisent des techniques d'intelligence artificielle pour réaliser des opérations complexes [RRH99, BG88].

Dans ce chapitre, nous combinons les MASs, les GAs, les MRFs et l'ICM pour définir une nouvelle approche évolutionnaire distribuée de segmentation d'images appelée MAS-GA.

Dans ce MAS-GA, nous considérons notre système comme un groupe d'agents qui coopèrent en vue de la réalisation d'un objectif local commun et, dans lequel des messages sont échangés dans un ordre coopératif pour l'achèvement d'un objectif global. Dans ce système MAS-GA, nous considérons un ensemble d'agents de segmentation structuré autour d'un agent de coordination dans une architecture de communication sous une topologie en étoile.

Les agents de segmentation sont capables de segmenter une image en utilisant l'algorithme ICM, chacun à partir de sa propre image initiale. Cependant, l'agent de coordination joue le rôle de diversification des images initiales. Celles-ci sont choisies et attribuées aux agents de segmentations afin de produire de nouvelles segmentations. En fait, les opérateurs génétiques permettent de produire de bons points de départ aux processus ICMs des agents de segmentation. L'intérêt de cette

diversification de données à travers ce processus génétique est de permettre au processus d'accéder aux bonnes segmentations.

Nous présentons notre approche comme suit :

- Premièrement : chaque agent de segmentation crée sa propre image initiale à partir de l'image observée. La procédure d'initialisation est basée sur l'algorithme K-moyennes suivi d'une légère perturbation aléatoire au niveau de la classification des pixels.
- Deuxièmement : chaque agent de segmentation utilise l'algorithme ICM pour segmenter l'image à partir de l'image initiale. Après la segmentation et son évaluation utilisant une fonction d'énergie, chaque agent de segmentation transmet l'image initiale, l'image segmentée, et la valeur de la fonction d'énergie de la segmentation vers l'agent de coordination.
- Troisièmement : l'agent de coordination reçoit les informations envoyées par les agents de segmentation, conserve la meilleure d'entre elles dans une variable appelée BestSegmentation. Ensuite, l'agent de coordination applique les opérateurs connus dans les GAs, soit le croisement et la mutation sur des images initiales courantes afin d'obtenir une nouvelle population d'images initiales. Celles-ci servent d'initialisations pour les agents de segmentation.
- Quatrièmement : le MAS-GA pour la segmentation d'images répète la deuxième et la troisième étape jusqu'à sa stabilité.

Dans cette approche coopérative, les différents agents de segmentation interagissent et coopèrent à travers l'agent de coordination pour réaliser des segmentations considérées comme des buts personnels. L'agent de coordination oriente ce travail afin de choisir et d'accéder à la bonne segmentation qui est vue comme un but commun.

Le résultat de cette coopération est l'émergence de nouvelles images sous-optimales initiales attribuées aux agents de segmentation. Cette nouvelle génération de images initiales permet aux agents de produire une nouvelle génération

de segmentations.

Puisque les agents sont coopératifs, un ou plusieurs d'entre eux améliorent le résultat des segmentations d'une manière significative. Les sémaphores sont utilisées pour résoudre les conflits des activités de cette coordination.

Le reste du chapitre est organisé comme suit : la deuxième section est une présentation des outils et concepts utilisés dans notre approche. La troisième section est consacrée à la description des MASs et les GAs suivie par la présentation de l'architecture de notre approche en section quatre. La section cinq est une concrétisation de cette conception par des résultats numériques sur différentes images. La dernière section est réservée à la conclusion et aux possibilités futures relatives aux extensions de notre approche.

5.2 Concepts de base et notations

Dans cette section, nous introduisons brièvement quelques outils et notations relatives aux MRFs que nous jugeons nécessaires pour le développement de notre approche MAS-GA.

Nous considérons une image S comme l'ensemble $S = \{1, \dots, t, \dots, MN\}$ représentant les niveaux de gris associés aux pixels dans une maille à MN -sites.

L'image idéale et l'image observée sont représentées par les vecteurs aléatoires suivants : $X = (X_1, \dots, X_t, \dots, X_{MN})$, $X_t \in \{1, \dots, C\}$, C est le nombre de catégories et $Y = (Y_1, \dots, Y_{MN})$.

La notion du système de voisinage est un concept très important dans les modèles MRFs.

Un système de voisinage $NS = (V_i \subset S, i \in S)$ est une collection de sous-ensembles V_i de S vérifiant les conditions suivantes : **(1)** $i \notin V_i$ et **(2)** $j \in V_i \Leftrightarrow i \in V_j$.

Une clique c est un ensemble de points voisins les uns aux autres. On peut écrire :

$$\forall r, t \in c, r \in V_t.$$

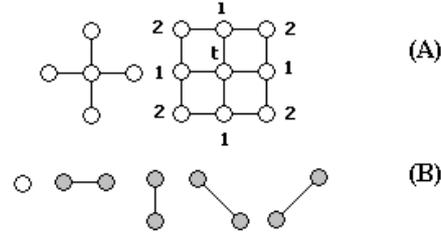


FIG. 5.1: Exemples de : (A) Systèmes de voisinages, (B) Cliques.

La structure du système de voisinage détermine l'ordre du MRF. Pour un premier ordre, le voisinage du site correspond à ses quatre sites voisins. La structure de clique pour un MRF second-ordre est illustrée dans la figure 5.1. L'ordre de voisinage un et deux est illustré dans la figure 5.1.

Soit le champ aléatoire $X = (X_1, \dots, X_{MN}) \in \Omega$.

On dit que X est un MRF respectant NS si les deux conditions sont vérifiées :

1. $\forall x \in \Omega : P(X = x) > 0$.
2. $\forall t \in S, x \in \Omega : P(x_t/x_j, j \in S - \{t\}) = P(x_t/x_j, j \in V_t)$.

Dans ce cas $P(X = x)$ suit la loi de Gibbs définie par : $P(X = x) = e^{-U(x)}/Z$ où $Z = \sum_{x \in \Omega} e^{-U(x)}$ est la fonction de partition, $U(x)$ est la fonction d'énergie :

$$U(x) = \sum_{t=1}^{MN} \sum_{r \in V_t} \theta_r \delta(x_t, x_r) \quad (5.1)$$

où θ_r sont les paramètres des cliques, $\delta(a, b) = -1$ si $a = b$, 1 sinon $P(X = x)$ est appelé la probabilité a-priori.

Le problème de la segmentation d'images basée sur les MRFs peut être transformé à l'estimation d'un processus étiquette x minimisant une fonction d'énergie donnée par l'équation suivante :

$$U(x/y) = \sum_{t=1}^{MN} \left[\ln(\sqrt{2\pi}\sigma_{xt}) + \frac{(y_t - \mu_{xt})^2}{2\sigma_{xt}^2} + \sum_{r \in V_t} (\beta \delta(x_t, x_r)) \right] \quad (5.2)$$

5.2.1 La procédure ICM

Notre approche se base principalement sur la procédure ICM. Les agents de segmentation utilisent la procédure ICM qui est présentée ainsi :

- 1) **Lire** une *image initiale* $X^{(0)}$. Cette image initiale est, soit créée par K -moyennes suivie par une légère perturbation ou envoyée par l'agent de coordination.
- 2) **Balayer** l'ensemble des sites étiquettes. Chaque site t visité à l'étape n est caractérisé par son état $x^{(n)}$ et par la configuration de son voisinage $V_t^{(n)}$. Son nouvel état $x^{(n+1)}$ est la valeur correspondant au maximum de la probabilité a-posteriori $P(\cdot/x^{(n)}, r \in V_t^{(n)})$.
- 3) **Répéter** l'étape **2.** un nombre donné d'itérations
- 4) **Sortir** l'*image segmentée* avec la *valeur de sa fonction d'énergie*.

Il est à noter que l'ICM n'a qu'une seule chance de trouver la bonne segmentation en fonction de la configuration initiale $X^{(0)}$. Dans le papier de Dubes et al. [DJNC90] intitulé "MRF model-based algorithms for image segmentation" publié dans IEEE Transactions on Pattern Analysis and Machine Intelligence, les résultats pratiques ont démontré que l'ICM est très efficace par rapport au SA et à l'algorithme "Maximum Posterior Method".

5.3 Le Concept des Systèmes Multi-Agents

Dans ce paragraphe, on montre l'utilité des paradigmes des MASs. On présente les notions d'agent, multi-agents et d'environnement qui sont les concepts clés de

ces systèmes. La notion d'agent est issue de l'évolution du domaine de l'intelligence artificielle distribuée.

A partir du moment où le contrôle des entités est décentralisé, les termes de système multi-agent (MAS) et d'agent apparaissent comme un paradigme de conception de systèmes artificiels [GBH87].

5.3.1 Définition de l'agent

On adopte une définition du concept d'*agent* selon Jacques Ferber [Fer99, Pic04] :

Un agent est une entité physique ou virtuelle capable d'agir (ou communiquer) sur son environnement de manière autonome et ce, en fonction de perceptions et connaissances partielles.

Le comportement de l'agent est guidé par un ou plusieurs objectifs individuels. Les agents sont destinés à être plongés dans un environnement afin d'effectuer une tâche comme déterminée par leurs compétences. La distribution des tâches sera guidée par les interactions entre agents.

Ferber distingue deux sous-types d'agents :

- *les agents situés qui évoluent dans un environnement physique, dont les actions concernent des modifications des objets voisins,*
- *les agents communicants dont les actions sont purement sociales (envoi de messages, d'intentions, etc.).*

Bien sûr, un agent peut être à la fois situé et communicant. Par exemple : un robot peut être capable de soulever des boîtes et de communiquer par radio.

5.3.2 Autonomie de l'agent

L'autonomie d'un agent peut être définie en trois points [AGO04] :

- les agents ont une existence propre indépendante de celle des autres,
- les agents sont capables de maintenir leur viabilité dans des environnements dynamiques, sans contrôleur extérieur,
- les agents sont capables de prendre une décision quant à leur comportement à venir (action, communication).

5.3.3 De l'agent aux Systèmes Multi-Agents

Introduire la notion des MASs implique le regroupement des agents dans un ensemble. Ceci nécessite la prise en compte des problématiques organisationnelles et collectives portant sur les entités, la dynamique et la structure [AGO04], contrairement aux systèmes mono-agent. Un agent au sein d'un système peut avoir un rôle ou une certaine tâche à remplir vis-à-vis des autres agents. La dynamique induite par le regroupement d'agents doit être prise en compte à la fois au niveau des agents (Quels sont leurs plans ? Quels services offrent-ils aux autres ? Quelles capacités collectives possèdent-ils ?) et au niveau du collectif (Quelles sont les interactions possibles ? Quelles collaborations/coopérations/formations peuvent-ils adopter ?). Enfin, la position des agents au sein de la société et dans le contexte est une chose primordiale. Les notions d'organisation, avec des modèles comme AGR (Agent/Groupe/Rôle) [FG98], ou avec des infrastructures collaboratives, sont des sujets de recherche importants dans le domaine multi-agents. Un MAS est donc un système composé d'agents autonomes ayant pour but une action collective. Les mécanismes permettant d'obtenir cette fonction prennent en compte les enjeux sociaux entre agents, comme la coopération. Dans ce mémoire, nous nous focalisons sur les aspects méthodologiques de la mise en place du comportement coopératif afin d'obtenir une approche efficace de la segmentation d'images.

5.3.4 La notion d'environnement

Jacques Ferber considère qu'un MAS est composé d'agents, d'objets, d'un environnement et d'opérations [Fer99]. Cette définition va à l'encontre des définitions

utilisées en biologie ou en physique pour l'auto-organisation et l'émergence, dans lesquelles l'environnement est tout ce qui n'est pas un agent. On distingue deux types d'environnements, physique et social. Pour un agent, l'environnement physique correspond à tous les objets que l'agent peut percevoir ou sur lesquels il peut agir.

L'utilisation de plusieurs agents intelligents isolés dans un même environnement n'a pas beaucoup d'intérêt. D'autre part, l'émergence des réseaux et des interconnexions du système impose nécessairement l'utilisation d'une société d'agents pour la résolution des problèmes complexes.

Ce chapitre est destiné à l'élaboration d'une architecture multi-agents formée d'un groupement d'agents qui interagissent les uns avec les autres. Il s'agit d'analyser, de décrire et de concevoir des environnements dans lesquels les agents peuvent interagir de façon efficace. Pour structurer et définir de tels environnements il est nécessaire d'inclure et d'utiliser des protocoles de communication et d'interaction. L'interaction permet d'entretenir des conversations tandis que la communication permet l'échange d'informations entre les agents.

5.4 L'architecture du MAS-GA

Notre approche combine les MASs, les GAs et l'algorithme ICM pour définir une nouvelle approche de segmentation d'images. Nous considérons un ensemble d'agents structurés autour d'un agent de coordination dans une architecture en étoile. Les agents de segmentation partitionnent une image observée à partir de configurations initiales différentes. L'agent de coordination crée et distribue de nouvelles configurations initiales pour les agents de segmentations. Cette diversification est réalisée par des opérateurs génétiques (croisement et mutation).

Nous considérons un agent comme un système informatique capable de réaliser des actions autonomes dans son environnement [Flo98].

5.4.1 Organisation de notre MAS-GA

L'organisation de notre approche est basée sur les MASs comme suit :

Le système est composé d'un ensemble d'agents de segmentation connectés autour d'un agent de coordination sous une architecture en étoile (voir Figure 5.3).

Chaque agent de segmentation réalise à temps complet un service puis attend l'arrivée d'une nouvelle configuration initiale pour lancer la segmentation. La méthode utilisée pour réaliser la segmentation est l'ICM. Cependant, l'agent de coordination diversifie les configurations initiales utilisées par les agents de segmentation en appliquant les opérateurs génétiques de croisement et de mutation (voir Figure 5.4).

Notre MAS-GA pour la segmentation d'images basée sur les MRFs opère comme suit :

1. **Initialisation du MAS-GA pour la segmentation d'images :** Chaque agent de segmentation crée aléatoirement une configuration sous-optimale à partir de l'image observée. Nous utilisons l'algorithme K-moyennes pour une configuration sous-optimale (classification). Les agents de segmentations perturbent cette classification en changeant les classes des pixels avec une légère probabilité p_c (nous avons fixé p_c à 0.005).

2. **Les tâches des agents de segmentation :**

Chaque agent de segmentation utilise l'algorithme ICM pour segmenter la même image observée. Toutefois; chacun d'eux commence par sa propre image initiale. Tous les agents de segmentation sont interconnectés à un agent de coordination dans une structure en étoile comme un réseau de communication (voir figure 5.3). Après ces segmentations, les agents transmettent les informations suivantes :

les configurations initiales, les images segmentées, ainsi que les valeurs d'énergies associées.

3. **Le rôle de l'agent de coordination :**

- Reçoit les différents messages et informations des agents de segmentation.
- Conserve la meilleure de toutes les segmentations dans une variable appelée BestSegmentation (cette segmentation est comparée à toutes les segmentations actuelles et passées).
- Applique l'opérateur génétique **le croisement** sur les configurations initiales aléatoirement afin d'enrichir et de diversifier la qualité des configurations initiales.
- Exécute **la mutation** sur une ou plusieurs configurations initiales. Quand un site étiquette est soumis à une mutation, il est localisé et modifié dans sa classe (l'alphabet).
- Envoie les nouvelles configurations initiales aux agents de segmentations

4. **La boucle du MAS** : le processus répète les étapes 2 et 3 jusqu'à la stabilité du système.

5.4.2 Coordination

Les agents existent et réalisent leurs activités dans une société. Ainsi, la coordination des agents est essentielle pour assurer l'achèvement de leurs objectifs d'une manière cohérente [Flo98].

Cette coordination peut impliquer la coopération. Dans ce cas, la société des agents travaille pour la réalisation d'un but commun. Par contre, ceci peut signifier compétition entre les agents de segmentation ayant des objectifs divergents (voir figure 5.2).

Dans cette architecture multi-agents pour la segmentation d'images, nous développons un modèle de coordination dans lequel les agents travaillent en interaction et en coopération pour leurs propres buts (segmentations locales) et arrivent par la suite à atteindre le but global qui est la bonne segmentation (voir figure 5.2).

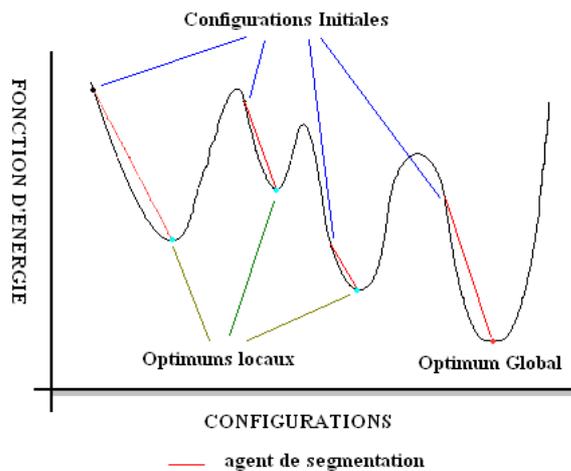


FIG. 5.2: Agents de segmentation à la recherche de l'optimum global.

5.4.3 Coopération

Le MAS-GA pour la segmentation d'images présenté dans ce chapitre peut être considéré comme une société coopérative. En effet, les agents agissent en interaction dans une action commune après identification d'un but commun.

La stratégie de coopération guide les interactions d'agents pour l'amélioration de leurs performances collectives.

En réalité, les agents de segmentation échangent des parties de leurs configurations initiales en utilisant des opérateurs génétiques à savoir le croisement et la mutation [Gol89, Hol75, Koz95]. Ceci dans un but d'améliorer la qualité des points de départ successifs.

La mutation permet d'assurer que l'évolution ne se bloque pas et rend chaque solution accessible par ce processus.

L'opérateur génétique de reproduction est basé sur le principe de l'évolution de Charles Darwin : '*survival of the fittest*' [Gol89, Hol75, Koz95]. En effet, l'GA est une heuristique utilisée pour la recherche et l'optimisation par l'application de son opérateur croisement et occasionnellement la mutation [Koz95]. Chaque individu correspond à l'image sous-optimale qui peut être une bonne configuration initiale par l'agent de segmentation.

À travers une série de générations utilisées par les agents de segmentation comme des points de départ, le MAS-GA pour la segmentation d'images tente de trouver une bonne configuration par l'élevage génétique d'une population d'images sous-optimales.

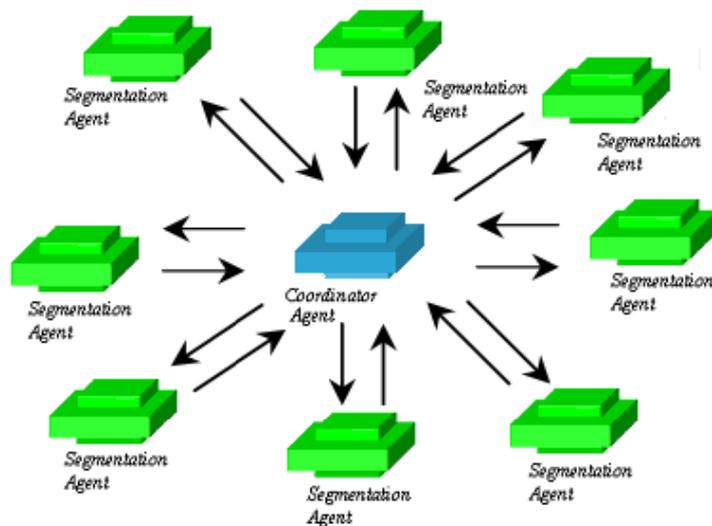


FIG. 5.3: Topologie en étoile du système.

5.4.4 Les opérateurs génétiques

5.4.4.1 Le croisement

Dans ce contexte, l'image initiale (image sous-optimale créée à partir de l'image observée en utilisant K-moyennes suivie par une légère perturbation) est considérée comme un chromosome où les sites étiquettes représentent les gènes. L'opérateur génétique croisement combine avec une probabilité de 0.9 le matériel génétique de deux parents pour produire des descendants (voir figure 5.5). Ces derniers représentent de nouvelles images de départ. Elles peuvent être utilisées par les ICMs des agents de segmentation afin de produire une bonne segmentation. En effet, l'opérateur croisement choisit deux parents et fixe des positions en lignes et en colonnes pour découper les deux images/parents afin d'effectuer les différents échanges entre

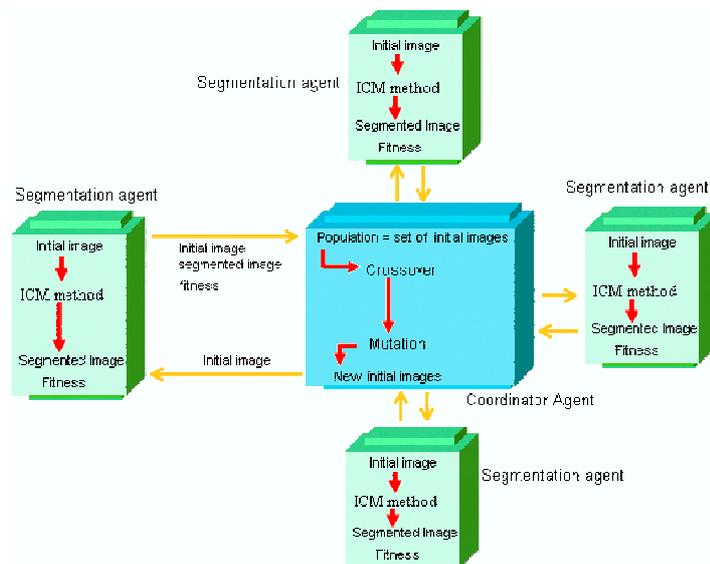


FIG. 5.4: Réseau de communication.

segments des images.

En effet, le croisement diversifie les images initiales utilisées par les agents de segmentation, ce qui permet d'éviter les problèmes de la convergence prématurée et d'échapper aux optimums locaux (voir Figure 5.6). Dans la figure 5.6, nous montrons que le second descendant est largement meilleur que le premier. En effet, cet enfant/image hérite les bonnes parties des deux parents (le carré et le cercle du premier parent et le triangle et l'étoile du second parent).

5.4.4.2 La mutation

La mutation est un événement rare extrêmement important dans les GAs. Quand dans un site (emplacement) l'étiquette est mutée, elle est aléatoirement choisie et remplacée par une autre catégorie de l'ensemble d'étiquettes (alphabet). La mutation modifie un chromosome simple du parent (image sous-optimale). Cette modification est répartie aléatoirement sur plusieurs gènes (sites étiquettes) d'un chromosome (image sous-optimale). Le résultat de ces opérateurs génétiques est une nouvelle génération des configurations sous-optimales attribuées en tant qu'images

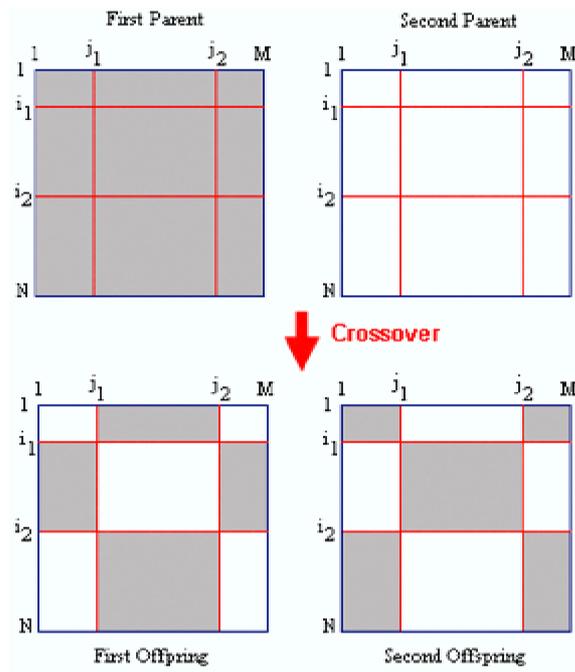


FIG. 5.5: Crossover de deux parents gris et blanc reproduisant deux descendants "métisses". i_1, i_2 sont les points lignes de croisement et j_1, j_2 sont les points colonnes.

initiales aux agents de segmentation. Ces nouvelles images de départ permettent aux agents de segmentation de produire une nouvelle génération d'images segmentées.

5.5 Implémentation et résultats expérimentaux

Dans cette section, nous montrons quelques résultats importants de notre application MAS. Ces expériences sont comparées à la méthode ICM et prouvent la robustesse de notre approche dans tous les cas. Nous avons comparé avec l'ICM pour son efficacité par rapport aux approches classiques, notamment sur le plan complexité [DJNC90].

Nous avons employé une valeur unique de $\beta = 1.5$ (voir le papier [DJNC90]) qui reste constante tout au long des expériences suivantes. La segmentation est évaluée par la fonction d'énergie $U(x/y)$ et aussi par un examen visuel. La Figure 5.7 montre

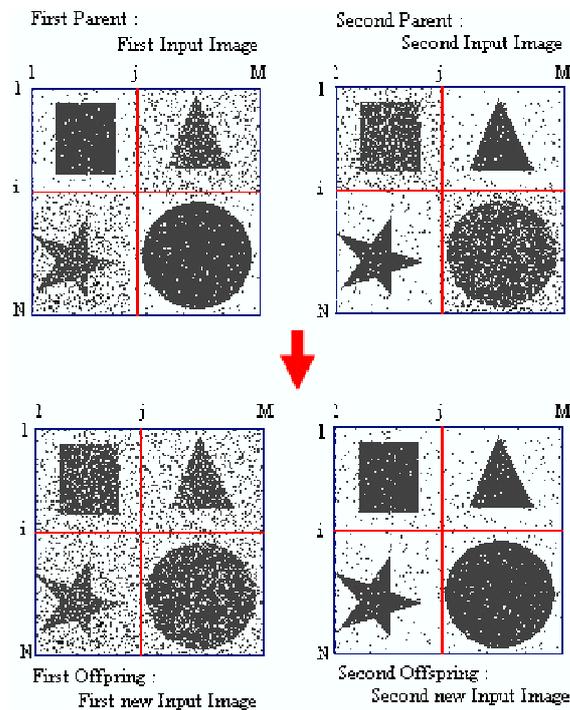


FIG. 5.6: Exemple illustrant l'importance du croisement dans l'amélioration des images initiales.

un exemple de l'image bruitée synthétique contenant trois classes avec différentes figures géométriques (rectangle, triangle, cercle, et étoile). On peut voir que les différentes régions sont nettement mieux segmentées en utilisant l'approche MAS en dépit de l'interférence de quelques régions. Dans l'ICM l'image est nettement moins tranchée.

Le graphe 5.7.(e) représente une comparaison entre l'ICM et la meilleure segmentation des agents (Meilleur ICM du MAS). Nous pouvons voir que la courbe de l'ICM du meilleur agent converge à une meilleure segmentation que celle de l'ICM. Cette robustesse est due à l'action de coopération qui offre de bonnes images initiales aux agents (au meilleur agent) afin de mieux segmenter. En fait, l'ICM a une seule chance de trouver la meilleure segmentation. En revanche, l'approche de segmentation MAS distribue cette tâche aux agents de segmentation et aide ces derniers par un apport de bonnes images sous-optimales initiales.

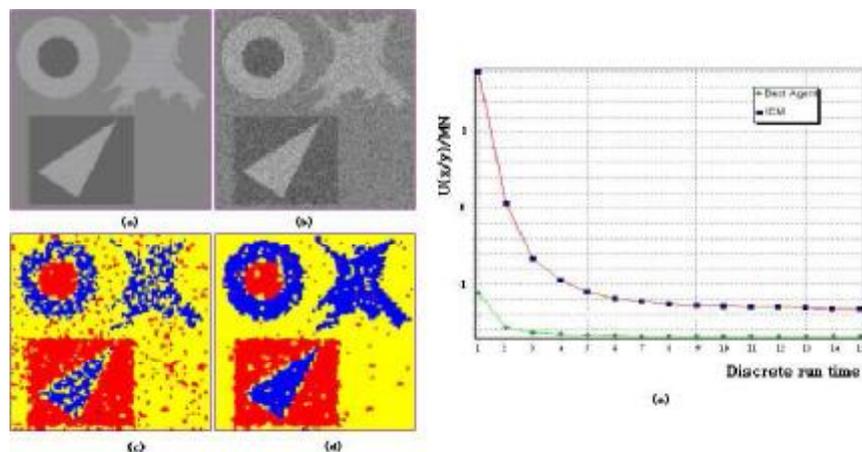


FIG. 5.7: Résultats de l'application MAS sur une image synthétique avec un nombre d'agents de segmentation=10, nombre d'itérations du MAS=100 et $C=3$. (a) Image synthétique, (b) image bruitée, (c) Image segmentée par ICM, (d) Image segmentée par MAS, (e) comparaison entre l'ICM et le meilleur agent.

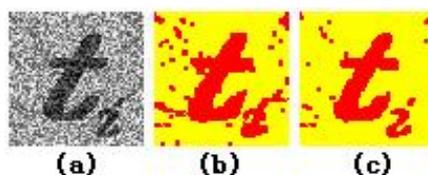


FIG. 5.8: Exemple de reconnaissance de caractère. (a) Image "caractères t_i ", (b) résultat ICM, (c) image segmentée du MAS. Nombre d'agents de segmentation=10, Nombre d'itérations du MAS=70 et $C = 2$.

Dans le deuxième exemple appelé "caractères t_i " (voir Figure 5.8), nous avons exécuté l'ICM et notre approche de segmentation d'images MAS sur l'image qu'on appelle "caractères t_i " corrompue par un bruit gaussien. Dans ce résultat, nous montrons encore une fois que la segmentation d'images MAS est meilleure que l'ICM.

Dans la figure 5.9, une image qui représente une pièce mécanique est segmentée par l'approche MAS. La différence avec l'algorithme ICM, est évidente au niveau de la région du dentier de la pièce.

Le graphe 5.10 présente l'évolution du processus de la segmentation par le MAS-GA de l'image t_i . A chaque itération du processus, nous considérons $(x/y)/(mn)$ la

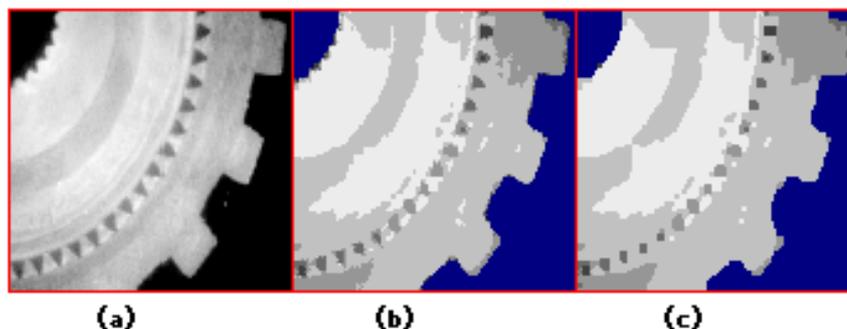


FIG. 5.9: Segmentation d'une scène réelle. (a) Image d'une pièce, (b) image segmentée du MAS-GA, (c) résultat ICM. nombre d'agents de segmentation=10, nombre d'itérations du MAS-GA=100 et $C = 4$.

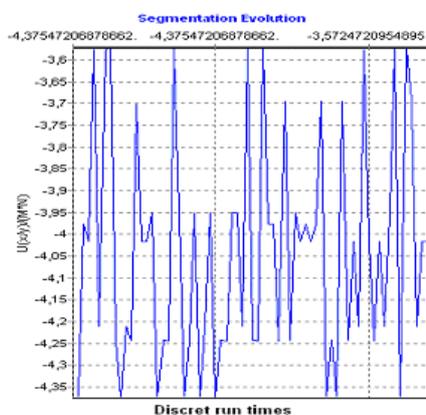


FIG. 5.10: Graphe d'évolution de la segmentation du MAS-GA.

valeur de l'agent réalisant le minimum de la fonction d'énergie. Ce graphe montre l'aspect d'intensification de la segmentation du MAS-GA. En fait, l'agent de coordination sauvegarde la meilleure des segmentations, ce qui permet aux agents de poursuivre la recherche de nouvelles configurations dans d'autres régions dans l'espace des solutions.

Dans la Figure 5.11, notre approche est appliquée sur une scène réelle représentée par une vue d'une maison. Le résultat de notre MAS-GA est meilleur que celui de l'ICM.

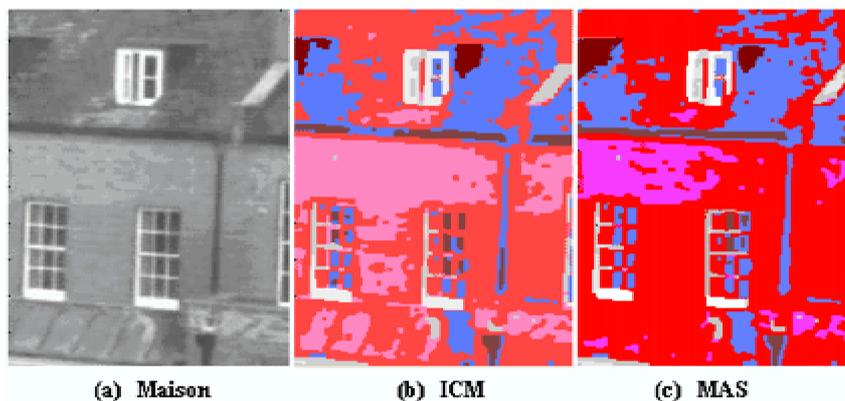


FIG. 5.11: Segmentation d'une scène réelle (Maison).

5.6 Conclusion

Dans ce chapitre, nous avons proposé une nouvelle approche évolutionnaire distribuée de segmentation d'images basée sur la théorie des MASs. Dans cette approche, les agents de segmentation exécutent les ICMs chacun à partir de son image sous-optimale. Cependant, l'agent de coordination sauvegarde la meilleure segmentation et diversifie ces images initiales en appliquant les opérateurs génétiques, les transmet aux agents de segmentation afin qu'ils produisent une nouvelle génération d'images segmentées.

Cette opération de diversification d'images initiales multiplie les chances d'un ou plusieurs agents d'obtenir une meilleure segmentation. Ainsi, ces agents tentent par une activité de compétition/coopération d'accéder à la meilleure configuration.

Les agents de notre MAS sont des entités autonomes et un agent ne peut avoir une connaissance précise de la structure interne des autres. Donc, des paradigmes supplémentaires pourront être ajoutés au rôle des agents.

Un nombre important d'agents peut accélérer le processus de segmentation et offrir une méthode pour le calcul parallèle.

Par ailleurs, l'évaluation de la segmentation peut améliorer considérablement le résultat de celle-ci par un jugement visuel. Ce jugement visuel de segmentation réalisé par un expert va pénaliser la valeur de la fonction objective.

En effet, dans plusieurs applications d'imagerie, il est préférable que l'évaluation de la segmentation soit faite par une mesure quantitative et par une évaluation visuelle. En effet, nous pouvons considérer cet expert comme agent intégré dans notre MAS. Cette perspective améliorera d'une manière significative l'action de coopération.

CHAPITRE 6

APPROCHES MAS-HYBRIDE ET CMAS POUR LA SEGMENTATION D'IMAGES BASÉE SUR LES MRFS

Nous avons proposé dans le chapitre précédent une approche distribuée pour la segmentation d'images basée sur les MRFS, les MASs et les GAs. Ce MAS-GA est basé sur une série d'opérations génétiques offrant des points de départ aux agents de segmentation dans le but de trouver la bonne segmentation. Dans ce chapitre, nous présentons deux améliorations de cette approche. La première vise à introduire la procédure MRF-EO, déjà développée dans le quatrième chapitre, comme une méthode de recherche locale dans l'GA. Cette hybridation améliore la performance de cette approche. Dans une autre amélioration, nous utilisons un système chaotique afin d'offrir à notre approche une efficacité au niveau de l'initialisation et de la mutation. Le but de l'introduction du système chaotique est de tirer profit de ses caractéristiques telles que la sensibilité aux conditions initiales, l'aspect d'ergodicité et l'aspect stochastique.

6.1 Introduction

Nous avons proposé dans le chapitre précédent une approche évolutionnaire distribuée MAS-GA basée sur une série d'opérations génétiques offrant des points de départs aux agents de segmentation dans le but de trouver la bonne segmentation.

L'GA est une méthode heuristique qui a récemment reçu beaucoup d'attention en raison de sa convenance dans les problèmes d'optimisation surtout combinatoires [MBP94, BL94, CDPY99, LD89, And99].

Les GAs peuvent trouver la solution optimale même lorsqu'il y a plusieurs pics dans les fonctions objectives. Cependant, un GA classique souffre du nombre considérable d'itérations demandées ainsi qu'une très grande taille de la population exigée pour trouver une bonne solution. Dans la première amélioration de l'approche MAS-GA, nous introduisons l'approche MRF-EO, déjà développée dans le quatrième chapitre, comme une méthode de recherche locale au niveau de l'GA. Nous utilisons cette méthode pour améliorer le processus génétique de cette nouvelle approche évolutionnaire distribuée.

En effet, la méthode de recherche locale introduite MRF-EO n'a pas de paramètre de contrôle et les états optimaux émergent spontanément sans aucune intervention extérieure. La mise à jour de quelques sites étiquettes dans une configuration provoque des interactions locales entre les entités de bas-niveau du système. Cette activité co-évolutionnaire permet au processus d'accéder à de nouvelles solutions à n'importe quelle phase d'exécution.

Dans ce chapitre, nous appelons notre nouvelle approche évolutionnaire distribuée MAS-Hybride pour la segmentation d'images [MBF06b] basée sur les MRFs.

En effet, nous utilisons un type d'GA hybride appelé "the Self Organized-Criticality Evolutionary Algorithm" (SOCEA) [KRT00]. Dans cette approche hybride, nous introduisons un modèle de Bak-Sneppen représenté par l'algorithme MRF-EO (voir chapitre 4). Ce type d'GA hybride est plus préformant que celui d'un GA standard. En effet, la mise à jour de quelques sites étiquettes dans une

configuration provoque des interactions locales entre les entités de bas-niveau du système ce qui rend chaque solution accessible par ce processus.

Notre approche MAS-Hybride apparaît comme un GA distribué classique (par exemple le modèle d'île "island model"), qui a pour but de rendre les GAs parallèles. Cependant, notre approche est complètement différente de ce type d'approche.

En effet, dans l'GA distribué, la population totale est divisée en sous-populations appelées "demes" résidant dans des entités (dans des papiers sont appelées îles en anglais "island"). Après un nombre prédéterminé de générations dans un GA, il y a seulement une population, mais dans les GAs distribués il y a plusieurs populations secondaires qui s'appellent les îles.

Par ailleurs, un GA normal qui opère sur une seule population est appelé "Canonical GA". Dans les GAs distribués, les opérations normales d'un GA sont effectuées en chaque île. A une certaine période, certains d'individus sont sélectionnés dans des sous populations d'îles et se déplacent vers d'autres îles. Cette opération est appelée migration.

Cependant, notre approche évolutionnaire distribuée MAS-Hybride est constituée d'un ensemble d'agents qui utilisent un ensemble de paradigmes d'une manière efficace pour trouver la bonne solution. En effet, dans MAS-Hybride nous considérons un ensemble d'agents qui coopèrent en vue de la réalisation d'un objectif local commun, et dans lequel des messages sont échangés dans un ordre coopératif via un GA hybride pour l'achèvement d'un objectif global.

Dans cette approche MAS-Hybride, nous avons ajouté d'une manière très simple un nouveau paradigme au niveau de l'agent de coordination. Cette flexibilité est due aux avantages qu'offrent les MASs.

L'approche MAS-Hybride opère en deux phases principales.

La première phase est l'initialisation et la seconde est la mise à jour.

- Dans la phase d'initialisation, chaque agent de segmentation crée sa propre image initiale à partir de l'image observée.
- Dans la phase de mise à jour, pour chaque cycle d'évolution du MAS-Hybride

les agents de segmentation utilisent les ICMs pour segmenter l'image chacun à partir de sa propre image initiale. Après, chaque agent transmet l'image initiale, l'image segmentée, et la valeur de la fonction d'énergie de la segmentation vers l'agent de coordination. Ce dernier reçoit les informations envoyées par les agents de segmentation, conserve la meilleure des segmentations. Ensuite, l'agent de coordination applique un processus génétique hybride sur la population courante dans le but de créer des nouvelles images initiales variées. Ces nouvelles images initiales seront attribuées aux agents de segmentation pour un nouveau processus de segmentation. En effet, l'agent de coordination accomplit les opérateurs connus dans les GAs, soit le croisement et la mutation, suivis par la méthode de recherche locale MRF-EO sur des images initiales courantes, afin d'obtenir une nouvelle population d'images initiales.

Dans une seconde amélioration, nous introduisons un système chaotique afin d'offrir une efficacité à notre approche MAS-GA (voir le chapitre précédent) au niveau de l'initialisation et de la mutation [MBF06b].

Dans la littérature des systèmes chaotiques et heuristiques, nous trouvons seulement peu de papiers traitant les heuristiques avec un système chaotique [CA95, MH04]. Dans le papier [CA95], les auteurs appliquent l'heuristique des réseaux neurones. Ils proposent une heuristique efficace combinant le SA classique avec un réseau de neurones chaotique. Récemment, Ji Mingjun et al. [MH04] ont proposé une application réussie d'attracteur chaotique au niveau de SA. Les caractéristiques des systèmes chaotiques ont permis sans ambiguïté l'amélioration de l'efficacité du SA classique [MH04].

Le but d'introduire le système chaotique est de tirer profit de ses caractéristiques telles que la sensibilité aux conditions initiales, ergodicité et aspect stochastique. En fait, il y a un risque potentiel qu'un processus évolutionnaire distribué bute sur un minimum local, particulièrement quand les sous-populations de petite taille sont employées, et si les bons individus sont employés en tant que parents initiaux [KAJ04]. Cependant, ce danger peut être évité en employant une initialisation

aléatoire efficace [KAJ04] ce qui coïncide exactement avec notre approche. Donc, le chaos est utilisé comme un générateur efficace de nombres pseudo-aléatoires, car on l'a appliqué de façon à ce qu'il puisse tirer profit de ses dispositifs intrinsèques offrant ainsi des séquences de nombres pseudo-aléatoires dans un ordre apériodique.

Le reste du chapitre est organisé comme suit : la deuxième section est une présentation des outils utilisés dans notre approche.

La troisième section est consacrée à la description de l'approche MAS-Hybride suivie par une concrétisation de cette conception par des résultats numériques. La section quatre est dédiée, à l'approche CMAS. La dernière section est réservée à la conclusion et aux possibilités futures.

6.2 Définitions, notations et modèle MRF utilisé

Dans cette section, nous introduisons quelques définitions jugées indispensables à la conception de notre approche hybride.

Le MRF est un processus stochastique discret dont les propriétés globales sont contrôlées au moyen de ses propriétés locales. Le modèle d'Ising accentue les MRFs et facilite leur utilisation dans différents domaines de l'application [KS80]. Dans ce chapitre, nous considérons aussi une image S par l'ensemble $S = \{1, \dots, t, \dots, MN\}$ représentant les niveaux de gris associés aux pixels dans une maille à MN – sites. L'image idéale et l'image observée sont représentées par les vecteurs aléatoires suivants : $X = (X_1, \dots, X_t, \dots, X_{MN})$, $X_t \in \{1, \dots, C\}$, C est le nombre de catégories et $Y = (Y_1, \dots, Y_{MN})$. Un système de voisinage $NS = (V_i \subset S, i \in S)$ est une collection de sous-ensembles V_i de S vérifiant les conditions suivantes : **(1)** $i \notin V_i$ et **(2)** $j \in V_i \Leftrightarrow i \in V_j$. Une clique c est un ensemble de points voisins les uns aux autres.

Le champ aléatoire $X = (X_1, \dots, X_{MN}) \in \Omega$ est un MRF respectant NS si :

1. $\forall x \in \Omega : P(X = x) > 0$.
2. $\forall t \in S, x \in \Omega : P(x_i/x_j, j \in S - \{i\}) = P(x_i/x_j, j \in V_i)$.

$P(X = x)$ suit la loi de Gibbs définie par : $P(X = x) = e^{-U(x)}/Z$ où $Z = \sum_{x \in \Omega} e^{-U(x)}$.

La fonction d'énergie à minimiser est :

$$U(x/y) = \sum_{t=1}^{MN} \left[\ln(\sqrt{2\pi}\sigma_{xt}) + \frac{(y_t - \mu_{xt})^2}{2\sigma_{xt}^2} + U(x_t) \right] \quad (6.1)$$

La somme $U(x_t) = \sum_{r \in V_t} \theta_r \delta(x_t, x_r)$

où θ_r sont des paramètres (nous supposons que $\theta_1 = \theta_2 = \theta_3 = \theta_4 = \beta$) et la fonction $\delta(a, b) = -1$ si $a = b$, 1 sinon.

6.3 L'approche MAS-Hybride proposée

6.3.1 Description de l'approche MAS-Hybride

Dans cette partie, nous introduisons l'heuristique optimisation extrême comme une méthode de recherche locale qui sera utilisée après les opérateurs génétiques croisement et mutation par l'agent de coordination [MBF06b]. Le but de combiner un GA avec une recherche locale comme optimisation extrême permet d'accélérer la convergence du processus vers l'optimum global et d'améliorer la recherche génétique aux étapes postérieures du cycle d'évolution [EHN04].

Après l'exécution des opérateurs génétiques, l'agent de coordination passe à l'étape de la procédure optimisation extrême sur une configuration sous-optimale x , sélectionnée aléatoirement. Les étapes de cette méthode sont clairement illustrées dans l'algorithme 5.

Nous présentons clairement les étapes du MAS-Hybride par l'algorithme 6.

Notre approche MAS-Hybride apparaît comme un GA distribué classique (modèle d'île [GWB92, LPG94, Lev96] "island model" par exemple), car il peut être considéré comme un GA parallèle distribué (voir figure 6.2).

Dans le modèle d'île "island model", la population est divisée en peu de sous-populations appelées les 'demes' et pour chaque sous-population un GA est exécuté séparément sur différentes machines ou processeurs.

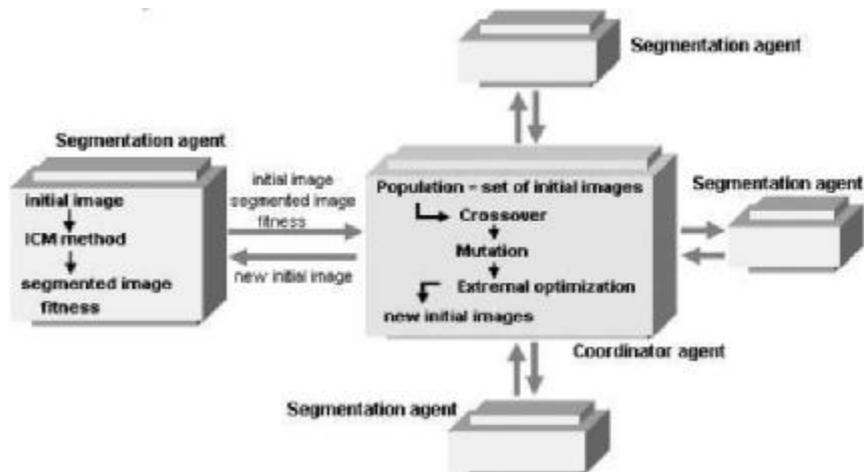


FIG. 6.1: Architecture du MAS-Hybride.

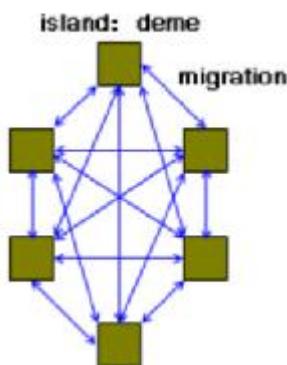


FIG. 6.2: Architecture distribuée sous un modèle d'île.

L'opérateur de migration permet le *métissage* des différentes sous-populations et est censé combiner les bons matériels génétiques qui émergent localement dans les différents "demes". Cependant, dans notre MAS-Hybride, chaque agent de segmentation accomplit sa propre segmentation à l'aide de l'ICM. En fait, le rôle de l'agent de segmentation peut être modifié et des paradigmes supplémentaires peuvent être facilement ajoutés. La population de MAS-Hybride se compose de différentes images initiales employées par des agents de segmentation en tant que points de départ de l'ICM. Li et al. [LPG94] présentent plusieurs approches migratoires du modèle d'île. D'une façon générale, le processus remplace les plus mau-

Algorithme 5 Les étapes de la recherche locale MRF-EO effectuée par l'agent de coordination.

1. Sélectionner aléatoirement un individu x parmi la population courante. Pour t calculer λ_t . Calculer $U = U(x/y)$. Poser $x_{best} = x$, $F_{best} = U$ et itération = 1.
 2. Trouver une permutation π des sites étiquettes $x_t : \lambda_{\pi(1)} \leq \dots \leq \lambda_{\pi(MN)}$.
 3. Pour $s = 1..MN$
 - Calculer la probabilité $P_s \propto s^{-\tau}$ où τ est un paramètre.
 - Générer un nombre aléatoire uniforme μ_s dans $[0, 1]$.
 - Si $\mu_s \leq P_s$ Alors modifier l'étiquette du site $\pi(s)$.
 4. Pour $t = 1..MN$ évaluer λ_t de x . Calculer $f = U(x/y)$.
 5. Si $f < F_{best}$ alors $x_{best} = x$ and $F_{best} = f$.
 6. itération=itération+1.
 7. Si itération \leq un nombre donné d'itérations alors goto 2.
 8. Itération = Itération +1. Remplacer x avec x_{best} .
-

vais k individus d'un "deme" par autres k individus venant d'autres populations, la plupart du temps les meilleurs des individus sont copiés. Cependant, dans le MAS-Hybride, l'agent de coordination diversifie les configurations initiales en utilisant les opérateurs génétiques suivi par la méthode de recherche locale optimisation extrême.

6.3.2 Applications

Cette partie vise à présenter deux résultats expérimentaux de notre approche MAS-Hybride. Les images choisies sont sonar et naturelle.

Dans la première, nous avons appliqué notre approche MAS-Hybride à une image réelle "SONAR" (voir Figure 6.3.(a)).

Les systèmes sonars utilisent les ondes acoustiques provoquées par la propagation d'une vibration mécanique pour transmettre et recevoir de l'information dans le milieu marin. Le terme SONAR désigne "SOund NAvigation and Ranging" et permet l'utilisation des ondes acoustiques pour la navigation et la transmission

Algorithme 6 Les étapes du MAS-Hybride pour la segmentation d'images.

1. **Initialisation** : Chaque agent de segmentation crée sa propre image initiale (sous-optimale) à partir de l'image observée en appliquant $K - moyennes$ puis en perturbant cette image initiale par la modification d'un ou plusieurs sites étiquettes.
 2. **Tâches des agents de segmentation** : Chaque agent de segmentation
 - utilise l'algorithme ICM pour segmenter l'image à partir de sa propre image initiale.
 - transmet l'image initiale, l'image segmentée, et la valeur de la fonction d'énergie de la segmentation vers l'agent de coordination.
 3. **Tâches de L'agent de coordination** :
 - reçoit les informations envoyées par les agents de segmentation,
 - sauvegarde la meilleure des segmentations dans une variable appelée BestSegmentation avec sa meilleure valeur objective dans U^* .
 - applique le croisement, la mutation sur des images initiales courantes,
 - applique la procédure MRF-EO (voir l'algorithme 5) sur une configuration sélectionnée.
 - transmet ces images descendantes aux agents de segmentation.
 4. **Le cycle du MAS-Hybride** : Le processus répète les étapes **2** et **3** jusqu'à un nombre donné d'itérations.
-

d'information (émission et réception).

C'est l'ensemble des systèmes de connaissance du milieu (sondeurs bathymétriques, sondeurs multifaisceaux, etc...) et de localisation et/ou détection de cibles (sonars militaires : exemple la guerre des mines de fond, sonars de pêche, etc...).

L'image de la Figure 6.3.(a) représente un fond marin sablonneux avec l'ombre d'une forme de roue. Dans la segmentation à deux-classes, un examen visuel et quantitatif montre l'efficacité de notre approche MAS-Hybride et ceci malgré le bruit de fond (speckle noise). Dans la Figure 6.3, on constate visuellement et quantitativement (voir le tableau 6.1) que notre approche MAS-Hybride est plus efficace que l'ICM, en dépit du bruit de fond existant sur l'image.

Le graphe présenté dans la Figure 6.3.(d) illustre clairement que l'approche MAS-Hybride intensifie la recherche, puis saute les barrières afin d'accéder finale-

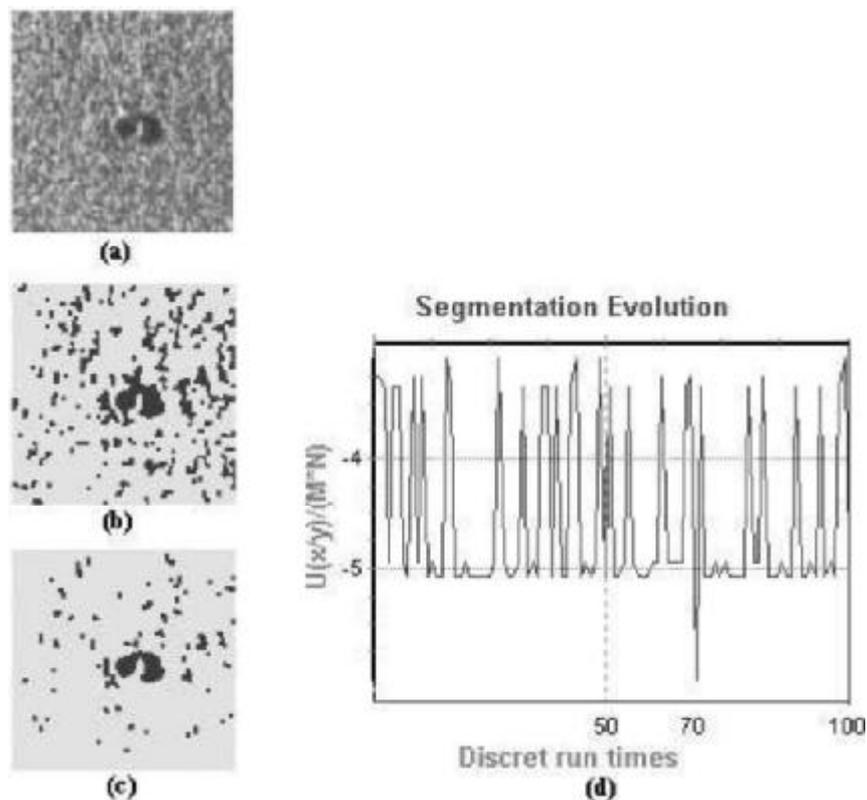


FIG. 6.3: Application du MAS-Hybride sur une image réelle. (a) image réelle, (b) résultat de l'ICM, (c) résultat du MAS-Hybride (d) Graphe d'évolution de la segmentation.

ment à une bonne solution dans l'itération 70. Par contre, l'ICM échoue et n'arrive pas à améliorer la qualité de la segmentation. En effet, l'image observée ne suit pas le modèle de bruit assumé.

Dans la seconde segmentation à quatre-classes de la scène naturelle illustrée dans la figure 6.4, nous montrons aussi la robustesse de notre approche qui décompose l'image en grandes régions (montagnes, ciel). Cependant, l'ICM tente sans succès de détailler la segmentation (voir la Figure 6.4 et le résultat numérique sur le tableau 6.1).

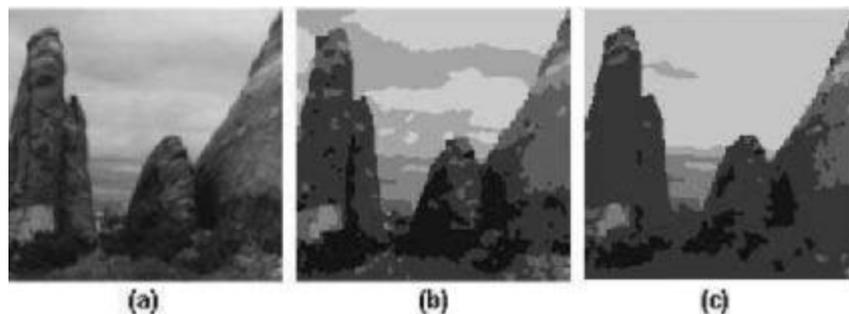


FIG. 6.4: Application du MAS-Hybride sur une scène naturelle. (a) Image observée, (b) résultat de l'ICM, (c) résultat du MAS-Hybride.

Expérience	Approche	$U(x^*/y)/MN$	Paramètres et convergence
Figure 6.3	ICM	-4.8093	Convergence = 9 itérations
	MAS-Hybride	-6.00	agents de segmentation =10, itérations =100
Figure 6.4	ICM	-4.3345	Convergence = 9 itérations
	MAS-Hybride	-4.4652	agents de segmentation =10, itérations =80

TAB. 6.1: Valeurs minimales de la fonction d'énergie et paramètres des expériences 6.4 et 6.3.

6.4 Système chaotique

Dans cette partie, nous introduisons le chaos dans l'ordre d'améliorer la performance de l'approche MAS-GA. Nous avons appelé cette nouvelle approche évolutionnaire chaotique CMAS [MBF06a].

Dans la littérature, nous trouvons peu d'articles parlant d'heuristiques combinées avec des systèmes chaotiques [CA95, MH04]. Dans le papier [CA95], Chen et Aihara appliquent les réseaux neurones. En effet, Chen et Aihara [CA95] proposent un SA chaotique en utilisant un réseau de neurone transitoirement chaotique, comme une méthode d'optimisation efficace aux problèmes d'optimisations combinatoires. Récemment, Ji Mingjun et al. [MH04] ont proposé une application d'attracteur chaotique à l'heuristique SA en appliquant les "maps" chaotiques. Ils proposent un nouvel algorithme appelé chaos SA démontrant sa nette supériorité par rapport au SA classique [MH04].

Dans ce travail, nous présentons un système chaotique comme un nouveau comportement d'agent afin d'améliorer l'efficacité du MAS-GA [MBF06a]. En effet, étant différent des comportements probabilistes classiques, les phénomènes du chaos sont un ensemble de comportements imprévisibles.

En réalité, nous tirons profit des caractéristiques spéciales du chaos, telles que la *propriété d'ergodicité*, l'*aspect stochastique* et la *sensibilité aux conditions initiales*, permettant à ce type d'approche d'échapper aux optima locaux et de converger vers un optimum global (voir le travail [MH04]). Nous présentons le map logistique unidimensionnel comme suit :

$$z_{k+1} = f(\mu, z_k) = \mu z_k (1 - z_k), \quad z_k \in [0, 1], \quad k = 0, 1, \dots \quad (6.2)$$

où z_k est la valeur de la variable z à la k^{ime} itération. Nous notons par μ le paramètre de bifurcation du système.

Dans l'équation 6.2 (voir la Figure 6.5), z_k prend toujours une valeur entre 0 et 1. La variable z_k représente le taux d'extinction où 0 représente l'extinction et 1 la population viable maximum. Le paramètre μ de bifurcation représente le taux de croissance de la population.

Selon l'équation 6.2, nous constatons que plus la valeur du taux de croissance est haute, plus haute est la future valeur affectée à la population.

Le second système chaotique utilisé dans l'algorithme "the chaos simulated annealing" [MH04] est inspiré du neurone chaotique [MH04, YC02]. Il est produit par un nouveau map chaotique défini par :

$$z_{k+1} = \eta z_k - 2 \tanh(\gamma z_k) \exp(-3z_k^3), \quad \eta \in [0, 1], \quad k = 0, 1, \dots \quad (6.3)$$

ou z représente l'état interne du neurone, η est un facteur d'atténuation de membrane du nerf et le deuxième terme de l'équation 6.3 donnée par $f(z_k) = 2 \tanh(\gamma z_k) \exp(-3z_k^3)$ désigne le feedback non-linéaire.

Ainsi, nous produisons une solution initiale selon un nouveau système chaotique en employant l'équation 6.3 à la place de l'équation 6.2.

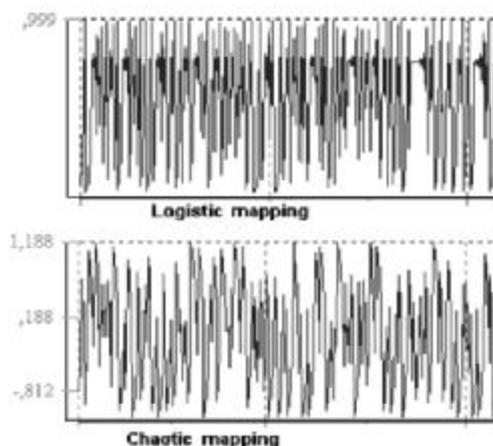


FIG. 6.5: Le "map logistic" et le nouveau "chaotic mapping" créé à partir du neurone chaotique. $\mu = 4$, $k = 300$, $z_0 = 0.01$, $\eta = 0.9$ et $\gamma = 5$.

L'application "chaos SA" a montrée sa supériorité par rapport au SA classique et a obtenue de très bons résultats [MH04]. Le CSA en utilisant l'équation 6.3 offre la meilleure précision en consommant plus de temps pour converger comparé au CSA utilisant le map logistique qui dépense relativement moins de temps-CPU [MH04].

Dans notre approche, nous utilisons la sensibilité extrême du chaos aux valeurs données [Lor63]. Dans l'initialisation chaotique (voir la fig. 6.6), nous créons une première configuration suivie d'une perturbation chaotique de certaines sites étiquettes.

6.4.1 Initialisation Chaotique

Dans la phase d'initialisation chaotique du CMAS (voir Figure 6.6), d'abord le processus crée une configuration initiale par K-moyennes, puis applique une perturbation chaotique sur certains sites étiquettes selon l'équation 6.4.

Pour un z_0 donné, les différentes variables chaotiques z_{k_s} , $s = 1, 2, \dots, MN$ sont produites par le "map" logistique (équation 6.2), k_s est un entier aléatoirement

génééré dans l'ensemble $\{1, \dots, 400\}$.

Posons $x^0 = (x_1^0, \dots, x_s^0, \dots, x_{MN}^0)$ l'image initiale créée en utilisant *K-moyennes*. Cette première image subit une perturbation chaotique en appliquant la formule suivante :

$$x_s^0 = \alpha[C * z_{k_s}] + (1 - \alpha)[C * w_{k_s}] \quad (6.4)$$

Pour un z_0 donné, les différentes variables chaotiques $z_{k_s}, s = 1, 2, \dots, MN$ sont produites par le map logistique (équation 6.2), et pour un w_0 donné, les différentes variables chaotiques $w_{k_s}, s = 1, 2, \dots, MN$ sont produites par le nouveau map chaotique (voir équation 6.3) où k_s est un entier aléatoirement généré dans l'ensemble $\{1, \dots, 400\}$ et α est un paramètre dans l'intervalle $[0, 1]$.

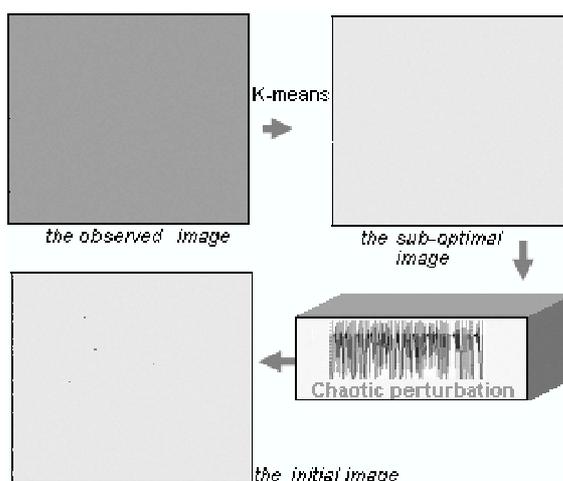


FIG. 6.6: Initialisation chaotique.

6.4.2 Mutation chaotique

Quand un site étiquette est muté, il est aléatoirement choisi et remplace son étiquette par une autre catégorie de l'ensemble d'étiquettes (alphabet) en employant un map chaotique. Nous appliquons aléatoirement une mutation chaotique (voir la

figure 6.7) avec une probabilité de 0.005. La mutation chaotique est appliquée de la même façon que l'initialisation.

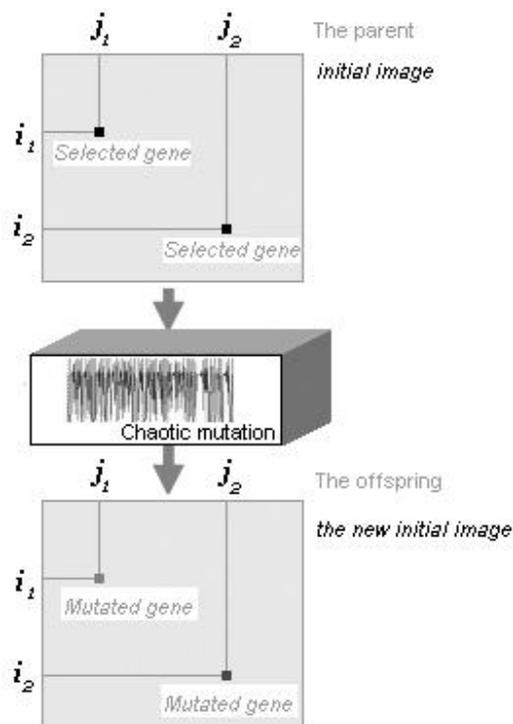


FIG. 6.7: Deux sites mutés d'une image initiale. (i_1, j_1) , (i_2, j_2) sont les deux sites mutés.

6.4.3 Résultats

Après l'introduction du système chaotique dans l'approche MAS-GA, nous appliquons cette nouvelle approche CMAS sur différentes images afin de la valider et de montrer son efficacité.

La figure 6.8 montre une image synthétique bruitée à trois couleurs avec différentes figures géométriques. Les différentes régions sont mieux segmentées par notre CMAS que par l'ICM (voir le tableau 6.2), ceci est en dépit de l'interférence et de la dégradation de quelques régions.

Dans la Figure. 6.9, le résultat de CMAS reste toujours meilleur que celui de

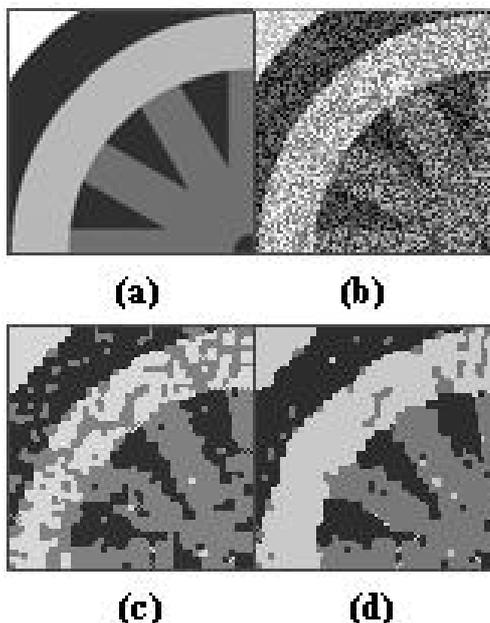


FIG. 6.8: Segmentation à trois-classes d'une image synthétique bruitée. Nombre d'itérations du CMAS=100.(a)image idéale (b) image bruitée (c) ICM (d) CMAS.

l'ICM (voir le tableau 6.2).

Dans la Figure 6.10, nous avons testé notre approche sur une vraie scène bruitée qui représente un certain nombre de boulons. La segmentation en deux classes de cette image démontre clairement la stabilité de notre approche comparée à l'ICM (voir le tableau 6.2).

Dans la segmentation à quatre-classes d'une image naturelle, représentant un ours (voir la fig. 6.11). Le résultat de segmentation par le CMAS est meilleur que celui de l'ICM, particulièrement au niveau des oreilles et de la langue.

Dans la figure 6.12.(a) représentant un ombre de fond d'un objet manufacturé à une forme géométrique, le résultat de CMAS est meilleur que celui de l'ICM. Dans la figure 6.12.(d) qui représente une image sonar impliquant des ombres d'une roche (voir la fig. 6.12.(d)). Cette segmentation montre clairement que notre approche trouve un meilleur résultat comparé à l'ICM qui ne permet pas d'éliminer l'effet de bruit de tache ("speckle noise") (voir fig. 6.12, images (e) et (f)).

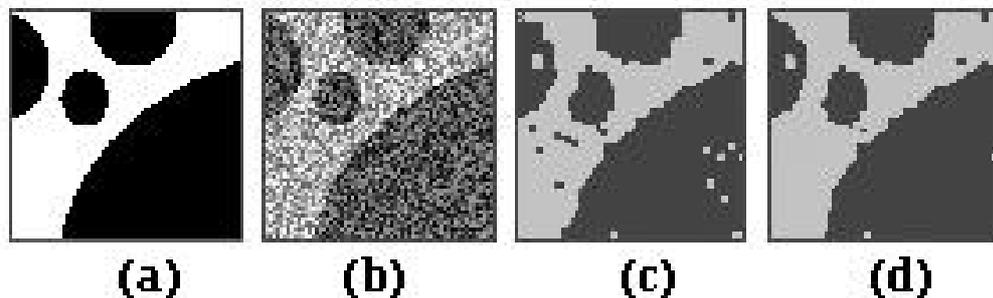


FIG. 6.9: Segmentation à deux-classes d'une image synthétique bruitée 64×64 . (a) image idéale, (b) image bruitée, (c) résultat de l'ICM, (d) résultat du CMAS.

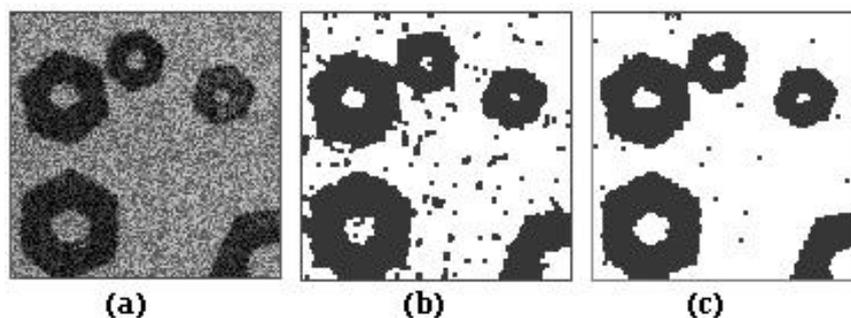


FIG. 6.10: Une segmentation à deux-classes d'une image bruitée 116×116 . (a) Image bruitée, (b) Résultat de l'ICM (c) résultat du CMAS.

6.5 Conclusion

Dans ce chapitre, nous avons proposé deux nouvelles approches évolutives distribuées pour la segmentation d'images. Ces approches sont des améliorations de l'approche MAS-GA présentée dans le chapitre précédent. Dans la première appelée MAS-Hybride, nous avons introduit un mécanisme co-évolutif inspiré du modèle de Bak-Sneppen au niveau de l'agent de coordination juste à la fin des opérations génétiques. Le but de cette hybridation est d'accélérer la convergence du processus vers l'optimum global et d'améliorer la recherche génétique aux niveaux des étapes postérieures du cycle d'évolution. Donc, la tâche de notre agent de coordination devient un GA hybride. La simplicité d'introduire un mécanisme co-évolutif inspiré du modèle de Bak-Sneppen réside dans le fait que les

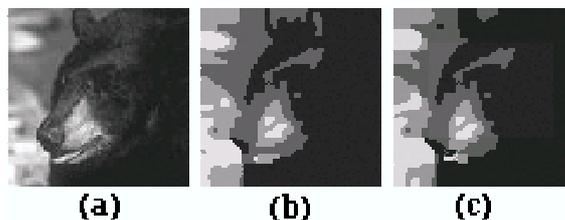


FIG. 6.11: Segmentation à quatre-classes d'un ours. (a) Image de l'ours, (b) résultat de l'ICM, (c) résultat du CMAS.

Experiment	Approach	$U(x^*/y)/MN$	Paramètres et convergence
Fig. 6.8.(c)	ICM	-3.378	Convergence = 9 itérations
Fig. 6.8.(d)	CMAS	-4.528	agents de segmentation =10, itérations=100 et $\alpha = 1$
Fig. 6.9.(c)	ICM	-3.6615	Convergence=8 itérations
Fig. 6.9.(d)	CMAS	-4.7351	agents de segmentation =10, itérations=100 et $\alpha = 1$
Fig. 6.10.(b)	ICM	-3.16	Convergence= 9 itérations
Fig. 6.10.(c)	CMAS	-6	agents de segmentation =10, itérations=100 et $\alpha = 1$
Fig. 6.11.(b)	ICM	-4.604	Convergence=10 itérations
Fig. 6.11.(c)	CMAS	-4.685	agents de segmentation =10, itérations=100 et $\alpha = 1$
Figure 6.12.(b)	ICM	-3.9488	Convergence =8 itérations
Figure 6.12.(c)	CMAS	-4.3494	agents de segmentation =10, itérations=100 et $\alpha = 0$
Figure 6.12.(e)	ICM	-2.5936	Convergence =8 itérations
Figure 6.12.(f)	CMAS	-4.0297	agents de segmentation =10, itérations=100 et $\alpha = 0$

TAB. 6.2: Valeurs minimales de la fonction d'énergie et paramètres des expériences de CMAS.

agents de notre approche sont des entités autonomes et un agent ne peut avoir une connaissance précise de la structure interne des autres. Un nombre important d'agents peut accélérer le processus de segmentation et offre une méthode très efficace pour le calcul parallèle.

Nous introduisons dans la deuxième approche appelée CMAS un système chaotique dans le but de tirer profit de ses caractéristiques spéciales telles que la propriété d'ergodicité, l'aspect stochastique et la dépendance à l'égard de l'initialisation. Ces caractéristiques permettent à notre approche d'échapper à l'optimum local et de converger vers l'optimum global. Les phénomènes du chaos sont un ensemble des comportements imprévisibles différents des comportements probabilistes classiques intégrés aux agents de notre approche CMAS.

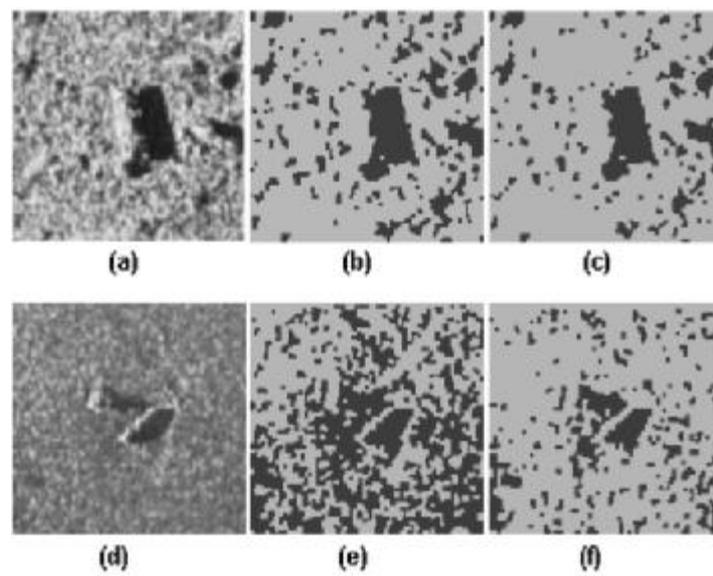


FIG. 6.12: Segmentation à deux-classes de deux images sonars provoquant un ombrage : (a) d'une roche, et (b) d'un objet cylindrique. (a) image sonar, (b) résultat de l'ICM de (a), (c) résultat de CMAS de (a), (d) image sonar, (e) résultat de l'ICM de (d), (f) résultat de CMAS de (d).

CHAPITRE 7

CONCLUSION GÉNÉRALE

Ce travail est consacré au domaine de la segmentation d'images basée sur les MRFs et les Algorithmes Evolutionnaires.

La première approche que nous avons proposée est une alternative aux méthodes classiques de segmentation d'images (SA et ICM, etc...). Dans cette méthode, nous combinons le modèle de Bak-Sneppen et les modèles MRFs pour définir une nouvelle approche de segmentation d'images. En effet, l'image est considérée comme un système-maille de Bak-Sneppen où chaque noeud correspond à une espèce (pixel, site étiquette, texture, etc...). Ces sites étiquettes sont des espèces dont les valeurs objectives sont évaluées par la probabilité a-posteriori. Les états de convergence SOC représentent exactement les estimations MAP.

Contrairement à l'algorithme ICM, l'aspect stochastique dans l'MRF-EO est préservé, et notre algorithme peut être lancé à partir d'une configuration quelconque.

N'étant pas basée sur un phénomène d'équilibre, notre approche ne nécessite qu'un petit nombre de paramètres, ce qui représente un avantage significatif par rapport au SA. Elle n'utilise pas de paramètres de contrôle et les états optimaux émergent spontanément sans aucune intervention extérieure.

La mise à jour de quelques sites étiquettes dans une configuration provoque des interactions locales entre les entités de bas-niveau du système. En effet, l'efficacité de notre approche est due aux larges fluctuations qui sont le résultat de la modification de quelques mauvais sites étiquettes. Cette activité co-évolutionnaire permet au processus l'accès à de nouvelles configurations dans l'espace de solutions à n'importe quel stade de l'exécution. N'utilisant qu'une seule copie de solution donne à notre approche un plus par rapport aux méthodes utilisant les GAs qui sont basée-population. Nous nous sommes intéressés, par la suite, à l'utilisation des MASs pour proposer une nouvelle approche de segmentation d'images basée

sur les MRFs. Nous considérons notre MAS comme une approche évolutionnaire distribuée basée sur la combinaison entre l'ICM, les GAs et les MRFs. Dans cette approche évolutionnaire distribuée, un groupe d'agents coopèrent pour la réalisation d'un objectif local commun, dans lequel des messages sont échangés dans un ordre coopératif en vue d'un objectif global.

Dans ce MAS, nous montrons comment utiliser un algorithme génétique pour produire et attribuer de bonnes configurations de départ à des processus de segmentation d'images déterministes. En effet, nous considérons un ensemble d'agents de segmentation structuré autour d'un agent de coordination. Les agents de segmentation exécutent les ICMs chacun à partir de son image sous-optimale. L'agent de coordination sauvegarde la meilleure configuration et diversifie ces images initiales en appliquant les opérateurs génétiques afin de produire une nouvelle génération d'images initiales. Ce processus de compétition/coopération donne aux agents de segmentation les meilleures probabilités d'accès à un résultat optimal. Des paradigmes supplémentaires peuvent être ajoutés aux rôles des agents de notre système en vue d'améliorer le processus.

Dans cette approche, nous proposons un modèle de coordination dans lequel des agents interagissent et coopèrent pour réaliser des segmentations sous-optimales en utilisant des ICMs, et enfin accéder à la segmentation optimale.

Le résultat de cette coopération est l'apparition de configurations sous-optimales variées attribuées aux agents de segmentation comme points de départ. Cette nouvelle génération de données discrètes initiales permet aux agents de produire une nouvelle génération de segmentation. Puisque les agents sont coopératifs, un ou plusieurs d'entre eux améliorent le résultat des segmentations d'une manière significative.

Une première amélioration de cette approche est d'introduire le mécanisme de co-évolution inspiré du modèle de Bak-Sneppen au niveau de l'agent de coordination juste à la fin des opérations génétiques. Donc, la tâche de notre agent de coordination devient un GA hybride. En outre, l'hybridation de l'GA avec une méthode de recherche locale améliore considérablement notre approche. En effet,

l'GA hybride diversifie d'une manière efficace les images initiales employées par les agents de segmentation ce qui permet au processus de surmonter les problèmes de la convergence prématurée et d'échapper aux optima locaux. Par ailleurs, nous avons introduit un système chaotique dans le but d'améliorer les performances de notre approche MAS-GA. En effet, le but est de tirer profit des caractéristiques spéciales du chaos telles que la propriété d'ergodicité, l'aspect stochastique et la dépendance à l'égard de l'initialisation. Etant différent des comportements probabilistes classiques, les phénomènes du chaos sont un ensemble de comportements imprévisibles. Ces caractéristiques permettent à ce type d'approche distribuée la garantie d'échapper à l'optimum local et de converger vers un optimum global.

Nous pouvons considérer que cette thèse constitue un premier pas vers des systèmes MASs à base d'Algorithmes Evolutionnaires hybrides. Une première perspective que nous envisageons de réaliser est d'utiliser le modèle d'îles comme architecture de conception.

Dans une seconde perspective, nous projetons d'utiliser notre approche MAS-Hybride en applications réelles comme par exemple l'imagerie médicale, la robotique. En effet, notre approche MAS-Hybride est extensible aux applications réelles comme par exemple la segmentation des images SAR et la classification des végétations issues des images satellites.

Bibliographie de l'auteur

Revue avec comité de lecture :

1. **K.E. Melkemi**, M.C. Batouche and S. Fougou, A MultiAgent System Approach for Image Segmentation using Genetic Algorithms and Extremal Optimization Heuristics, **Pattern Recognition Letters, elsevier**, special issue on Evolutionary Computer Vision and Image Understanding, Guest Editors, G. Ollague, E. Lutton and S. Cagnioni, Vol. 27, Issue. 11, pp. 1230-1238, 2006.
2. **K.E. Melkemi**, M.C. Batouche and S. Fougou, MRF model-based approach for Image Segmentation using a Chaotic MultiAgent System, in I. Bloch, A. Petrosino, and A. G. B. Tettamanzi (Eds.) : WILF'2005, **LNAI 3849, Revised Selected Papers** of WILF'2005 Milan, Crema Italy, Special Session Soft Computing on Image Processing SCIP, pp. 344353, 2006, Springer-Verlag Berlin Heidelberg 2006.

Chapitres de livres tirés des conférences internationales avec referees :

1. **K.E. Melkemi** and M.C. Batouche, MRF model-based algorithm using Extremal Optimization, Book Chapter in Advances in Systems Engineering, Signal Processing and Communications, N. Mastorakis Editor, WSEAS 2002, ISPRA2002, Chiclana Spain. pp.115-121, ISBN : 960-8052-69-6.
2. **K.E. Melkemi**, M.C. Batouche and S. Fougou, MRF and MultiAgent System based Approach for Image Segmentation, **IEEE International Conference on Industrial Technology** 2004, Hamamat, Tuisia, 8-12 December 2004. IEEE Catalog Number : 04TH8771C, ISBN : 0-7803-8663-9, vol. 3,pp. 1499-1504.

Conférences nationales :

- K.E. Melkemi**, M.C. Batouche, Une approche pour la segmentation des images en utilisant Optimisation extrême. Journées d'études sur : Vision, Vie Artificielle et Traitement d'images (VVATI'2003), Université de Jijel 2003.

BIBLIOGRAPHIE

- [AAS85] N. Ahuja, B. An, and B. Schachte. Image representation using Voronoi tessellation. *Comp. Vision Graphics, Image Processing*, 29, 1985.
- [AGO04] F. Arlabosse, M. P. Gleizes, and M. Occello. Méthodes de conception. *Systèmes Multi-Agents, Arago Edts et Doc.*, 29 :137–171, 2004.
- [And99] P. Andrey. Selectionist Relaxation : Genetic Algorithms applied to image segmentation. *Image and Vision Computing*, 17(3) :175–187, 1999.
- [AT94] P. Andrey and P. Tarroux. Unsupervised image segmentation using a distributed genetic algorithm. *Pattern Recognition*, 27(5) :659–673, 1994.
- [AT98] P. Andrey and P. Tarroux. Unsupervised segmentation of Markov random field modeled textured image using Selectionist Relaxation. *IEEE trans. on PAMI*, 20(3) :252–262, March 1998.
- [AY81] T. Asano and N. Yokota. Image segmentation scheme for low level computer vision. *Pattern Recognition*, 14, 1981.
- [Bak96] P. Bak. *How Nature Works*. Springer, New York, 1996.
- [BDBR04] E. G. P. Bovenkamp, J. Dijkstra, J. G. Bosch, and J. H. C. Reiber. Multi-agent segmentation of IVUS images. *Pattern Recognition*, 37 :647–663, 2004.
- [Bes74] J. Besag. Spatial interaction and the statistical analysis of lattice systems. *Jou. of the Royal Stat. Soc., Series B*, 36 :192–236, 1974.
- [Bes86] J. Besag. On the statistical analysis of dirty images. *Journal of Royal Statistics Society*, 48 :259–302, 1986.
- [Bes89] J. Besag. Towards bayesian image analysis. *Journal of Applied Statistics*, 16(3), 1989.

- [BG88] A. H. Bond and L. Gaser. Readings in distributed artificial intelligence. *Morgan Kaufmann, San Mateo, CA*, 1988.
- [BL94] B. Bhanu and S. Lee. Genetic learning for adaptive image segmentation. *Kluwer Academic Press*, 1994.
- [Boe99] S. Boettcher. Extremal Optimization and Graph Partitioning at the Percolation Threshold. *J. Physics A : Mathematical and General*, 32(28) :5201–5211, July 1999.
- [Boe03] S. Boettcher. Extremal optimization. *New Optimization Algorithms to Physics, Alexander K. Hartmann and Heiko Rieger (Eds.)*, Wiley-VCH Verlag Berlin GmbH, pages 1–27, 2003.
- [Bou95] Charles A. Bouman. Markov random fields and stochastic image models. *Tutorial Presented at : IEEE International Conference on Image Processing, Washington D.C.*, October 1995.
- [BP00] S. Boettcher and A.G. Percus. Nature’s Way of Optimizing. *Artificial Intelligence*, 119(1–2) :275–286, May 2000.
- [BP01] S. Boettcher and A. G. Percus. Optimization with Extremal Dynamics. *Physical Rev. Letters*, 86(23) :689–700, June 2001.
- [BP03] S. Boettcher and A. G. Percus. *Extremal Optimization : an evolutionary local-search algorithm*. Computational Modeling and Problem Solving in the Networked World. Dordrecht, Netherlands, h.k. bhargava and n. ye edition, 2003.
- [BR00] S. A. Barker and P. J. W. Rayner. Unsupervised image segmentation using markov random field models. *Pattern Recognition*, 33 :587–602, 2000.
- [Bry79] J. Bryant. On the clustering of multidimensional pictorial data. *Pattern Recognition*, 11, 1979.
- [BS93] P. Bak and K. Sneppen. Punctuated equilibrium and criticality in a simple model of evolution. *Physical Rev. Letters*, 71(24) :4083–4086, December 1993.

- [BTW87] P. Bak, C. Tang, and K. Wiesenfeld. Self-Organized Criticality : An explanation of the $1/f$ noise. *Physical Rev. Letters*, 59(4) :381–384, July 1987.
- [CA95] L. N. Chen and K. Aihara. Chaotic simulated annealing by a neural network model with transient chaos. *Neural Networks*, 8(6) :915–930, 1995.
- [CDM⁺96] A. Colorni, M. Dorigo, F. Maffioli, V. Maniezzo, and M. Trubian G. Righini. Heuristics from nature hard combinatorial optimisation problems. *International Transactions in Operational Research*, 3(1), 1996.
- [CDPY99] S. Cagnoni, A. B. Dobrzeniecki, R. Poli, and J. C. Yanch. Genetic Algorithm-based Interactive Segmentation of 3D medical images. *Image and Vision Computing*, 17 :881–895, 1999.
- [CJ93] R. Chellappa and A. K. Jain. Markov Random Fields : Theory and Application. *Academic Press, San Diego*, 1993.
- [CP97] E. Cantu-Paz. A survey of parallel genetic algorithms. *Technical Report 91003, Illinois Genetic Algorithms Laboratory, University of Illinois at Urbana-Champaign*, 17 :881–895, 1997.
- [DE87] H. Derin and H. Elliott. Modeling and segmentation of noisy and textured images using Gibbs random fields. *IEEE Trans. on PAMI*, 9 :39–55, 1987.
- [DJ89] R. C. Dubes and A. K. Jain. Random field models in image analysis. *Journal of Applied Statistics*, 16(2) :131–164, 1989.
- [DJNC90] R. C. Dubes, A. K. Jain, S. G. Nadabar, and C.C.Chen. MRF model-based algorithms for image segmentation. *IEEE Trans. on PAMI*, pages 808–814, 1990.
- [DMJ03] E. Duchesnay, J. J. Montois, and Y. Jacquelet. Cooperative agents society organized as an irregular pyramid : a mammography segmentation application. *Pattern Recognition Letters*, 24 :2435–2445, 2003.

- [DS95] K. A. DeJong and J. Sarma. On decentralizing selection algorithms. *Proceedings of the conference on Genetic Algorithms*, 1995.
- [EDCG84] H. Elliott, H. Derin, R. Cristi, and D. Geman. Application of the Gibbs distribution to image segmentation. *In Proceedings of the International Conference on Acoustic, Speech and Signal Processing*, 32(5) :1–4, 1984.
- [EHN04] T. Elmihoub, A. A. Hopgood, L. Nolle, and A. Battersby. Performance of hybrid genetic algorithms incorporating local search. *in Proc. 18th Euro. Simul. Multiconf. Graham Horton (c) SCS Europe*, pages 154–160, 2004.
- [Fer99] J. Ferber. Multi-agent system : An introduction to distributed artificial intelligence. *Harlow : Addison Wesley Longman*, 1999.
- [FG98] J. Ferber and O. Gutknecht. Aalaadin : A meta-model for the analysis and design of organizations in multi-agent system. *in ICMA98*, 1998.
- [Flo98] Adina Magda Florea. Introduction to Multi-Agent Systems. *International Summer School on Multi-Agent Systems, Bucharest*, 1998.
- [GBH87] L. Gasser, C. Braganza, and N. Herman. MACE : A Flexible Testbed for Distributed AI Research. *Distributed Artificial Intelligence, Research Notes on Artificial Intelligence*, pages 119–152, 1987.
- [GD04] Robert M. Gray and Lee D. Davisson. An introduction to statistical signal processing. *Cambridge University Press*, 2004.
- [GG84] S. Geman and D. Geman. Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *IEEE Trans. on PAMI*, 6(6) :721–741, 1984.
- [GG86] S. Geman and C. Graffigne. Markov random field image models and their applications to computer vision. *Proceedings of the International Congress of Mathematicians : Berkeley*, pages 1496–1517, August 1986.
- [GM85] S. Geman and D. McClure. Bayesian image analysis : An application to single photon emission tomography. *In Proceedings of the Statistical Computing Section, Washington, DC.*, pages 12–18, 1985.

- [Gol89] D. E. Goldberg. Genetic algorithms in search : Optimization and machine learning. *Addison Wesley*, 1989.
- [GWB92] V. S. Gordon, D. Whitley, and A. Böhn. Dataflow parallelism in genetic algorithms. *Parallel Problem Solving from Nature*, pages 533–542, 1992.
- [Hol75] J. H. Holland. Adptation in naturel and artificiel systems. *University of Michigan Press*, 1975.
- [HP76] S. L. Horowitz and T. Pavlidis. Picture segmentation by traversal algorithm. *Journal of ACM*, 23, 1976.
- [HS85] R. M. Haralick and L. G. Shapiro. Survey : image segmentation. *Computer vision, Graphics and Image Processing*, 29 :100–132, 1985.
- [KAJ04] Rafal Kicingier, Tomasz Arciszewski, and Kenneth De Jong. Evolutionary Design : Island-Model Based Optimization of Steel Skeleton Structures. *in Tall Buildings, CEC'2004*, 2004.
- [Kat94] Zoltan Kato. Modélisations markoviennes multiresolutions en vision par ordinateur, application à la segmentation d'images spot. *PhD Thesis, University of Nice*, 1994.
- [KGV83] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi. Optimization by Simulated Annealing. *Science*, 220(4) :671–680, May 1983.
- [Koz95] J. R. Koza. Survey of genetic algorithms and genetic programming. *in Proc. of the Wescon95-Conf. Record : Microelectronics, Communications Technology, Producing Quality Products, Mobile and Portable Power, Emerging Technologies, San Francisco, CA, USA*, 1995.
- [KPK00] E. Y. Kim, S. H. Park, and H. J. Kim. A genetic algorithm-based segmentation of Markov random field modeled images. *IEEE Signal Processing Letters*, 7(11), 2000.
- [KRT00] Thiemo Krink, Peter Rickers, and René Thomsen. Applying self-organised criticality to evolutionary algorithms. *Parallel Problem Solving from Nature-PPSN VI*, 1 :375–384, 2000.

- [KS80] R. Kindermann and J. L. Snell. Markov Random Fields and Their Applications. *Contemporary Mathematics, Amer. Math. Soc., Providence, Rhode Island, USA*, 1980.
- [KZB92] Z. Kato, T. Zerubia, and M. Berthod. *Satellite image classification using a Metropolis dynamics*. Proc. of ICQSSP, San Francisco, 1992.
- [LA87] P. J. M. Van Laarhoven and E. H. L. Aarts. *Simulated Annealing : Theory and Applications*. D. Reidel edition, 1987.
- [LD89] S. Lakshmanan and H. Derin. Simultaneous parameter estimation and segmentation of Gibbs Random Fields using Simulated Annealing. *IEEE Trans. on PAMI*, 11 :799–813, 1989.
- [Lev96] D. Levine. User’s guide to the PGAPack parallel Genetic Algorithm library. 1996.
- [Li01] S. Z. Li. Markov random field modeling in image analysis. *Springer*, 2001.
- [Lor63] E. N. Lorenz. Deterministic non-periodic flow. *J. Atmos. Sci.*, 20, 1963.
- [LP93] V. Lefèvre and Y. Pollet. Bbi : un système multi-agent d’aide à la photo-interprétation. *13ème journées internationales en intelligence artificielle, systèmes experts et langages naturelles, Avignon, France*, pages 473–482, 1993.
- [LP94] V. Lefèvre and Y. Pollet. Multi-agent system for visual integration. *IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, Las Vegas, USA*, pages 731–738, 1994.
- [LPG94] S. C. Lin, W. F. Punch, and E. D. Goodman. Coarse-grain Genetic Algorithms, Categorization and New Approaches. *in Sixth IEEE Parallel and Distributed Processing*, pages 28–37, 1994.
- [LT99] J. Liu and Y. Y. Tang. Adaptive image segmentation with distributed behaviour-based agents. *IEEE trans. on Pattern Analysis and Machine Intelligence*, 21(6) :544–551, 1999.

- [Lut99] E. Lutton. Algorithmes génétiques et fractales. *Dossier d'habilitation à diriger des recherches, Université de Paris XI Orsay*, Février 1999.
- [MB02a] Kamal E. Melkemi and Mohamed Batouche. MRF model-based algorithm for image segmentation using extremal optimization. *Advances in Systems Engineering, Signal Processing and Communications, in N. Mastorakis (Editor) WSEAS press, ISBN : 960-8052-69-6.*, pages 115–121, 2002.
- [MB02b] S. Meshoul and M. Batouche. Robust point correspondence for image registration using optimization with Extremal Dynamics. *Lect. Notes Comput. Sc.*, 2449 :330–337, 2002.
- [MBF04] Kamal E. Melkemi, Mohamed Batouche, and Sebti Foufou. MRF and MultiAgent System based Approach for Image Segmentation. *IEEE International Conference on Industrial Technology IEEE ICIT'2004, Hamamat, Tunisia, ISBN : 0-7803-8662-0, IEEE Catalog Number : 04TH8771C*, 3 :1499–1504, 2004.
- [MBF06a] Kamal E. Melkemi, Mohamed Batouche, and Sebti Foufou. MRF-based Image Segmentation using A Chaotic MultiAgent System. *International Workshop on Fuzzy Logic and Applications WILF'2005, Session : Soft Computing in Image Processing, Milan, Crema, Italy, in I.Bloch, A.Petrosino, and A. Tettamanzi (editors), Proceedings of WILF 2005, Springer-Verlag (Berlin Heidelberg), Lecture Notes on Artificial Intelligence (LNAI) series, Revised Selected Papers, volume no.3849*, pages 344–353, 2006.
- [MBF06b] Kamal E. Melkemi, Mohamed Batouche, and Sebti Foufou. A MultiAgent System Approach for Image Segmentation Using Genetic Algorithms and Extremal Optimization Heuristics. *Pattern Recognition Letters, elsevier, Special Issue on Evolutionary Computer Vision and Image Understanding, G. Ollague, E. Lutton and S. Cagnioni (Ass. Eds.)*, 27 :1230–1238, 2006.

- [MBP94] Y. Zhang M. Bhandarkar and W. D. Potter. An edge detection technique using genetic algorithm-based optimisation. *Pattern Recognition*, 27(9) :1159–1180, 1994.
- [MD96] A. Colorni M. Dorigo, V. Maniezzo. The ant system : Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man and Cybernetics, Part B.*, 26(1) :29–41, 1996.
- [MH04] Ji Mingjun and Tang Huanwen. Application of Chaos Simulated Annealing. *Chaos, Solitons and Fractals*, 21, 2004.
- [Mon87] O. Monga. An optimal region growing algorithm for image segmentation. *International Journal on Pattern Recognition and Artificial Intelligence*, 1(3) :351–376, 12 1987.
- [Mon90] O. Monga. Segmentation d’images : Où en sommes nous? *Rapport de Recherche numéro 1216, INRIA Recquencourt*, 4 1990.
- [MRR⁺53] N. Metropolis, A. Rosenbluth, M. Rosenbluth, A. Teller, and E. Teller. Equation of state calculation by fast computing machines. *Journal of Chem. Physics*, 21 :1087–1092, 1953.
- [OB03] S. Ouadfel and M. Batouche. Mrf-based image segmentation using ant colony system. *Electronic Letters on Computer Vision and Image Analysis*, 2(2) :12–24, 2003.
- [Pap92] T. N. Pappas. An addaptive clustering algorithm for image segmentation. *IEEE trans. on Signal Processing*, 40 :901–914, 1992.
- [Pav77] T. Pavlidis. Structural Pattern Recognition. *Springer Verlag*, 1977.
- [Pic04] Gauthier Picard. Méthodologie de développement de systèmes multi-agents adaptatifs et conception de logiciels à fonctionnalité émergente. *Thèse de Doctorat de l’Université Paul Sabtier, Toulouse III, France*, December 2004.
- [PSRa03] C. Porquet, H. Settache, S. Ruan, and all. Une plate forme multi-agent pour la segmentation d’images : étude des stratégies de coopération

- contour-région. *Congrès Francophone de Vision par Ordinateur, Orasis, Gerardmer, France*, pages 413–422, 2003.
- [PSWH84] T. C. Pong, L. G. Shapiro, L. T. Watson, and R. M. Haralick. Experiments in segmentation using a facet model region grower. *Comp. Vision Graphics, Image Processing*, 25, 1984.
- [Qui01] Isabelle Quidu. Classification multi-vues d’un objet immergé à partir d’images sonar et de son ombre portée sur le fond. *Thèse de doctorat de l’université de Bretagne occidentale*, december 2001.
- [RDG03] N. Richard, M. Dojat, and C. Garbay. Multi-agent Approach for Image Processing : A Case Study for MRI Human Brain Scans Interpretation. *in AIME*, 2003.
- [RRH99] A. Rares, M. J. T. Renders, and E. A. Hendriks. Mapping image analysis problems on multi-agent systems. *Technical Report, MCCWS Project information and Communication, Theory Group, TU Delft*, November 1999.
- [Sch02] Thorsten Schnier. Evolutionary Computation. *Lecture 13, School of Computer Science, University of Birmingham*, November 2002.
- [Sys89] G. Syswerda. Uniform crossover in genetic algorithms. *Proceedings of the third International Conference on Genetic Algorithms. San Mateo, CA*, 1989.
- [SZC⁺00] T. Sziranyi, J. Zerubia, L. Czuni, D. Geldreich, and Z. Kato. Image segmentation using markov random field model in fully parallel cellular network architectures. *A Real-Time Imaging*, 6 :195–211, 2000.
- [TJ90] M. Tuceryan and A. K. Jain. Texture segmentation using voronoi polygones. *IEEE trans. on PAMI*, 13 :211–216, 1990.
- [VRB03] C. J. Veenman, M. J. T. Reinders, and E. Backer. A cellular coevolutionary algorithm for image segmentation. *IEEE Transactions on Image Processing*, 12 :304–316, March 2003.

- [YC02] L. Yang and T. Chen. Application chaos in genetic algorithms. *Commun Theor Phys*, 38 :168–172, 2002.
- [ZM97] Song Chun Zhu and David Mumford. Prior learning and Gibbs reaction-diffusion. *IEEE Trans. on PAMI*, 19(11), 1997.
- [ZWM98] Song Chun Zhu, Yingnian Wu, and David Mumford. Filters, Random Fields and Maximum Entropy(FRAME) : Towards a Unified Theory for Texture modeling. *Intern. Jour. of Computer Vision*, 27(2), 1998.

Annexe I

Probabilités et variables aléatoires

Dans cette annexe, nous présentons les définitions jugées nécessaires pour l'élaboration de cette thèse ainsi que les notations qu'on a adoptés. Notons par I l'événement certain (celui qui se produit dans chaque essai). Soit A et B deux événements quelconques. L'événement $A \cap B$ désigne l'événement où tous les deux se produisent. A et B sont mutuellement exclusifs s'ils ne peuvent pas se produire au même temps.

I.1 Définition d'une probabilité

Nous définissons la probabilité comme une mesure $P(A)$. La probabilité d'un événement A est le nombre $P(A)$ qui satisfait les axiomes suivants :

1. $P(A)$ est positif (non-négatif) : $P(A) \geq 0$,
2. La probabilité d'événement certain est 1 : $P(I) = 1$,
3. Si A et B sont deux événements mutuellement exclusifs , alors la probabilité de l'union est la somme des deux probabilités :
Si $A \cap B = \phi$ Alors $P(A \cup B) = P(A) + P(B)$.

propriétés :

1. Pour A un événement, $P(A^c) = 1 - P(A)$, A^c désigne l'événement complémentaire de A .
2. $P(A) \leq 1$.
3. Posons ϕ l'ensemble vide, alors $P(\phi) = 0$.
4. Soient $A_i, i = 1, 2, \dots, K$ une partition finie de I (on note parfois l'événement certain par Ω), i.e. Si $A_i \cap A_j = \phi$ quand $i \neq j$ et $\cup_{i=1, K} A_i = I$ alors $P(B) = \sum_{i=1, K} P(A_i)$ pour une probabilité donnée.

(Si $A \cap B = \phi$ Alors $P(A \cup B) = P(A) + P(B)$)

I.2 Définition d'une Variable Aléatoire

Une variable aléatoire X est une fonction dont le domaine est l'espace I , qui assigne le nombre $X(\xi)$ à chaque événement élémentaire $\xi \in I$ tel que :

1. L'ensemble $\{X \leq x\}$ est un événement pour tous les x .
2. $P(X = -\infty) = P(X = +\infty) = 0$.

I.3 Définition d'une fonction de répartition ou distribution

Soit X une variable aléatoire, la fonction :

$$F(x) = P(X \leq x) \tag{I.1}$$

est dite fonction de répartition ou fonction de distribution pour tous x .

I.4 Définition d'une fonction de densité

Soit X une variable aléatoire. On appelle la fonction de densité f de la variable aléatoire X la dérivée de la fonction de répartition F :

$$f(x) = \frac{dF(x)}{dx}. \tag{I.2}$$

Après avoir défini quelques fonctions utiles pour caractériser une Variable Aléatoire, nous définissons les paramètres les plus importants d'une variable aléatoire qui sont l'espérance mathématique (ou la valeur moyenne) et la variance (l'écart-type).

I.5 Définition de l'espérance mathématique

On définit l'espérance mathématique d'une variable aléatoire X par l'intégrale suivante :

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx \quad (\text{I.3})$$

où $f(x)$ est la fonction de densité de X .

Propriétés : les propriétés suivantes sont évidentes :

1. $E\{a.X\} = a.E\{X\}$, a est une constante et X est une variable aléatoire.
2. $E\{X + Y\} = E\{X\} + E\{Y\}$, X et Y sont deux variables aléatoires indépendantes.

I.6 Définition de la variance et de l'écart type

La variance d'une variable aléatoire dont la moyenne est μ est donnée par la formule suivante :

$$\sigma^2 = \int_{-\infty}^{+\infty} (x - \mu)^2 f(x) dx \quad (\text{I.4})$$

σ est appelée l'écart type.

I.7 Définition des moments d'une variable aléatoire

Les moments m_k d'une variable aléatoire X sont définis comme suit :

$$m_k = E\{X^k\} = \int_{-\infty}^{+\infty} x^k f(x) dx \quad (\text{I.5})$$

Soient X et Y deux variables aléatoires. On définit dans la suite la distribution jointe et la densité jointe. Nous remarquons que ces définitions peuvent être généralisées à n variables aléatoires.

I.8 Définition de la distribution jointe

Soient X et Y deux variables aléatoires. On définit la distribution jointe des deux variables aléatoires X et Y par :

$$F_{XY}(x, y) = P\{X \leq x, Y \leq y\} \quad (\text{I.6})$$

I.9 Définition de la densité jointe

On définit la densité jointe des deux variables aléatoires X et Y , qui ont une distribution jointe différentiable jusqu'à l'ordre deux par :

$$f_{XY}(x, y) = \frac{\partial^2 F_{XY}(x, y)}{\partial x \partial y} \quad (\text{I.7})$$

Ces définitions peuvent être généralisées à n variables aléatoires.

I.10 Définition de la co-variance

Soient X et Y deux variables aléatoires, la covariance de X et Y est définie par :

$$\text{cov}(X, Y) = E\{(X - \mu_X)(Y - \mu_Y)\} \quad (\text{I.8})$$

Le rapport suivant :

$$r = \frac{E\{(X - \mu_X)(Y - \mu_Y)\}}{\sqrt{E\{(X - \mu_X)^2\}E\{(Y - \mu_Y)^2\}}} \quad (\text{I.9})$$

est appelé le coefficient de corrélation.

Dans les paragraphes suivants, nous examinons la théorie de la probabilité Bayésienne.

L'idée générale dans cette théorie est que toutes les probabilités sont conditionnelles. Cependant, pour simplifier les notations, nous allons utiliser $P(A)$ au lieu de $P(A/.)$.

I.11 Définition de la probabilité conditionnelle

Soit C un événement dont la probabilité est positive. La probabilité conditionnelle de A sachant C est définie par :

$$P(A|C) = \frac{P(A \cap C)}{P(C)} \quad (\text{I.10})$$

Il y a deux règles pour manipuler les probabilités :
la règle de multiplication et la règle d'addition.

La règle de multiplication est introduite par l'équation :

$$P(A, B|C) = P(A|C)P(B|A, C) \quad (\text{I.11})$$

Tandis que la règle d'addition est donnée par la formule suivante :

$$P(A \cap B|C) = P(A|C) + P(B|C) - P(A, B|C) \quad (\text{I.12})$$

I.12 Théorème de la probabilité totale

Soient n événements A_1, \dots, A_n mutuellement exclusifs dont la somme est l'événement certain :

$$A_i \cap A_j = \phi, \forall i \neq j, i, j \in \{1, \dots, n\} \quad (\text{I.13})$$

$$\cup_{i=1}^n A_i = I \quad (\text{I.14})$$

L'équation suivante est satisfaite pour n'importe quel événement B :

$$P(B) = \sum_{i=1}^n P(B|A_i)P(A_i) \quad (\text{I.15})$$

Voici le théorème le plus important dans la théorie de probabilité bayésienne :

I.13 Théorème de Bayès

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (\text{I.16})$$

La probabilité $P(A|B)$ est appelée la probabilité a posteriori et $P(A)$ est appelée la probabilité a priori de A .

I.14 Définition de la distribution conditionnelle

Soit C un événement ayant une probabilité positive. La distribution conditionnelle d'une variable aléatoire X est donnée par :

$$F_X(x|C) = P(X \leq x|C) = \frac{P(X \leq x, C)}{P(C)} \quad (\text{I.17})$$

I.15 Définition de l'indépendance conditionnelle

Soient X_1 , X_2 et X_3 trois variables aléatoires avec X_1 est conditionnellement indépendant de X_2 sachant X_3 si :

$$f(x_1, x_2|x_3) = f(x_1|x_3)f(x_2|x_3) \quad (\text{I.18})$$

I.16 Définition de la distribution normale

On dit qu'une variable aléatoire X suit une loi normale ou une distribution normale si sa fonction de densité est une gaussienne donnée par l'équation I.19 (voir Figure I.1).

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (\text{I.19})$$

où μ est la moyenne et σ désigne l'écart type de X .

I.17 Définition de la distribution jointe normale

Soient X et Y deux variables aléatoires. On dit que les variables aléatoires X et Y ont une distribution jointe normale si leur fonction de densité est donnée par :

$$f(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-r^2}} e^{-\frac{\frac{(x-\mu_X)^2}{\sigma_X^2} + \frac{(y-\mu_Y)^2}{\sigma_Y^2} - \frac{2(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y}}{2(1-r^2)}} \quad (\text{I.20})$$

où μ_X est la moyenne et σ_X désigne l'écart type de X respectivement et μ_Y est la moyenne et σ_Y désigne l'écart type de Y respectivement, r est le coefficient de corrélation.



FIG. I.1: (A) Fonction de densité d'une variable aléatoire normale, (B) Densité jointe de deux variables aléatoires normales.

Remarques :

On peut montrer que si deux variables aléatoires ont une distribution jointe normale alors elles sont aussi marginalement normales. L'inverse n'est vrai que si elles sont *conditionnellement indépendantes*.

Soient X_1, X_2, \dots, X_n n variables aléatoires. On dit que \vec{X} (on note X) le vecteur aléatoire $X^T = (X_1, X_2, \dots, X_n)$.

Pour la dimension n , la distribution jointe est donnée par :

$$f(x_1, x_2, \dots, x_n) = f(\vec{X}) = \frac{1}{\sqrt{(2\pi)^n - |\Sigma|}} e^{-\frac{1}{2}(\vec{X} - \vec{\mu})^T \Sigma^{-1} (\vec{X} - \vec{\mu})} \quad (\text{I.21})$$

où

$$\Sigma = \begin{pmatrix} \sigma_{11} & \dots & \sigma_{1n} \\ \dots & \dots & \dots \\ \sigma_{n1} & \dots & \sigma_{nn} \end{pmatrix}, \mu = \begin{pmatrix} \mu_1 \\ \dots \\ \mu_n \end{pmatrix} \quad (\text{I.22})$$

Dans le cas des variables aléatoires X_i qui sont non-corrélées, alors leur matrice de co-variance Σ est une matrice diagonale.

I.18 Bruit blanc

Un modèle de bruit utile dans le traitement d'images est le bruit blanc [42]. La séquence (X_1, X_2, \dots) est dite blanche si elle est une séquence de Markov :

$$P(X_k | X_l, l < k) = P(X_k) \quad (\text{I.23})$$

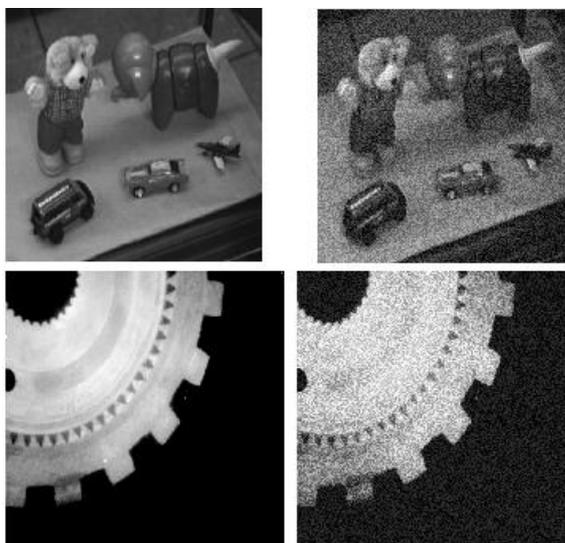


FIG. I.2: Deux Images Bruitées

Si nous supposons que les X_k sont des variables aléatoires normales, la séquence $\{X_1, X_2, \dots\}$

est appelé bruit blanc gaussien.

I.19 Définition : convergence

La séquence X_n converge vers X avec une probabilité de 1 si pour l'ensemble des événements ξ tel que :

$$\text{Lim}_{n \rightarrow \infty} X_n(\xi) = X(\xi) \quad (\text{I.24})$$

a une probabilité égal à 1. On peut donc écrire

$$P(X_n \rightarrow X) = 1, \text{ pour } n \rightarrow \infty \quad (\text{I.25})$$

I.20 Définition : convergence dans le sens des moindres carrées

La séquence X_n converge vers X dans le sens des moindres carrées si

$$\text{Lim}_{n \rightarrow \infty} E\{|X_n - X|^2\} = 0 \quad (\text{I.26})$$

Annexe II

Processus Stochastiques et Chaînes de Markov

II.1 Définition d'un processus stochastique

Un processus stochastique (ou processus aléatoire) est un modèle mathématique décrivant un phénomène qui évolue dans le temps d'une manière que l'observateur ne peut prédire [GD04].

Le phénomène peut être une séquence de valeurs réelles mesurant le voltage ou la température, flot binaire de données à partir d'un ordinateur, flot binaire de données modulées à partir d'un modem, une séquence de lancement d'une monnaie, données radiométriques ou photographies à partir d'une sonde dans un espace profond, etc... [GD04].

On définit un processus stochastique par un ensemble de variables aléatoires $(X(t)), t \in T$, où T est appelé l'ensemble d'indices, t est appelé temps.

Si T est continu on parlera d'un processus stochastique continu et si T est discret on parlera d'une suite de variables aléatoires ou d'un processus stochastique discret X_t .

A chaque événement $\xi \in I$, nous attribuons une fonction de temps $X(t, \xi)$. La famille de ces fonctions est appelée un processus stochastique. L'autocorrélation d'un processus stochastique $X(t)$ est le moment joint des variables aléatoires $X(t_1)$ et $X(t_2)$:

$$R(t_1, t_2) = E\{X(t_1)X(t_2)\} \quad (\text{II.1})$$

L'auto-covariance est la covariance de $X(t_1)$ et $X(t_2)$:

$$C(t_1, t_2) = E\{(X(t_2) - \mu(t_1))(X(t_2) - \mu(t_2))\} \quad (\text{II.2})$$

Après combinaison des deux équations précédentes, nous obtenons :

$$C(t_1, t_2) = R(t_1, t_2) - \mu(t_1)\mu(t_2) \quad (\text{II.3})$$

II.2 Définition d'un processus strictement stationnaire et processus faiblement stationnaire

Un processus est *strictement stationnaire* si les processus $X(t)$ et $X(t + \varepsilon)$ ont les mêmes statistiques pour n'importe quel ε .

Un processus est *faiblement stationnaire* si sa valeur moyenne est constante et son autocorrelation ne dépend que de $r = t_1 - t_2$

$$E\{X(t)\} = \mu, \quad E\{X(t+r)X(t)\} = R(r) \quad (\text{II.4})$$

II.3 Chaînes de Markov

II.3.1 Définition d'un processus markovien

On dit qu'un processus stochastique $X(t)$ est un processus markovien si pour chaque n et pour chaque $t_1 < t_2 < \dots < t_n$, on a

$$P(X(t_n) \leq x_n | X(t_{n-1}), \dots, X(t_1)) = P(X(t_n) \leq x_n | X(t_{n-1})) \quad (\text{II.5})$$

II.3.2 Définition d'une chaîne de Markov

Soit $(X_i) = (X_1, X_2, \dots, X_k, \dots)$ une séquence des variables aléatoires avec les valeurs possibles a_1, \dots, a_n . (X_i) est dite Chaîne de Markov si la propriété markovienne est satisfaite :

$$P(X_n = a_{i_n} | X_{n-1} = a_{i_{n-1}}, \dots, X_1 = a_{i_1}) = P(X_n = a_{i_n} | X_{n-1} = a_{i_{n-1}}) \quad (\text{II.6})$$

Cette propriété Markovienne signifie qu'étant donné l'ensemble des états passés et présents du système, la probabilité d'un état futur quelconque est indépendante de son état passé et dépend seulement de son état actuel. On parlera dans ce cas de processus sans mémoire.

Les probabilités conditionnelles $P(X_{t+1} = j | X_t = i)$ sont dites probabilités de transition et on les note :

$$P_{ij}^t = P(X_{t+1} = j | X_t = i) \quad (\text{II.7})$$

Les probabilités non-conditionnelles sont notées par :

$$p_i(n) = P(X_n = a_i). \quad (\text{II.8})$$

Si P_{ij}^t ne dépendra plus du temps, i.e. on a $\forall t, s \quad P_{ij}^t = P_{ij}^s$ et dans ce cas P_{ij}^t sera notée P_{ij} constituant ainsi une matrice carrée d'ordre N si N est le nombre des états possibles dans lesquels peut se trouver le processus.

Les éléments P_{ij} vérifient les propriétés suivantes :

$$\forall i, j \quad P_{ij} \in [0, 1] \quad (\text{II.9})$$

$$\sum_{j=1}^N P_{ij} = 1, \quad \forall i = 1, \dots, N \quad (\text{II.10})$$

$M = (P_{ij})$ est appelée matrice stochastique.

II.3.3 Propriétés particulières d'une matrice stochastique

Soit M une matrice stochastique :

1. M^r est une matrice stochastique, $r \in \mathbf{N}$.
2. Si toutes les lignes de M sont identique alors $M^r = M, r = 1, 2, \dots$
3. Si M est de la forme :

$$M = \begin{pmatrix} A & 0 \\ 0 & B \end{pmatrix} \quad (\text{II.11})$$

où A et B sont des sous-matrices carrées et 0 est une matrice carrée nulle, alors le système décrit par cette matrice et partant d'un état de A ne peut jamais se trouver dans état inclus dans B et réciproquement. Dans ce cas, on dit que la chaîne est *réductible*.

Les deux sous-systèmes d'états de A et B sont isolés et forment des sous graphes disjoints.

Remarquons que :

$$M^n = \begin{pmatrix} A^n & 0 \\ 0 & B^n \end{pmatrix} \quad (\text{II.12})$$

4. Soit la matrice suivante :

$$M \begin{pmatrix} A & 0 \\ C & B \end{pmatrix} \quad (\text{II.13})$$

où A, B et C sont des sous-matrices carrées et 0 est une matrice carrée nulle, alors la forme de la matrice stochastique M est conservée à la puissance à laquelle on l'élève :

$$M^n = \begin{pmatrix} A^n & 0 \\ M_n & B^n \end{pmatrix}, \quad (\text{II.14})$$

où $M_n = M_{n-1} * A + B^{n-1} * C$, avec $M_1 = C$.

5. Soit

$$M = \begin{pmatrix} 0 & D \\ C & 0 \end{pmatrix} \quad (\text{II.15})$$

où A, B et C sont des sous-matrices carrées et 0 est une matrice carrée nulle, alors

$$M^{2n} = \begin{pmatrix} (D.C)^n & 0 \\ 0 & (C.D)^n \end{pmatrix} \quad (\text{II.16})$$

et

$$M^{2n+1} = \begin{pmatrix} 0 & (C.D)^n.D \\ (C.D)^n.C & 0 \end{pmatrix} \quad (\text{II.17})$$

Donc, on peut dire que le système oscille entre deux sous-ensembles d'états. Dans ce cas de figure le processus stochastique est dit périodique.

II.3.4 Propriété d'ergodicité d'une chaîne de Markov

Si la limite de $M^m = \tilde{M}$ quand m tend vers $+\infty$, où \tilde{M} est une matrice stochastique ne possédant aucun élément nul, on dit que le système est *ergodique*, stable en probabilité, ou encore qu'il possède un régime permanent, et M est dite matrice ergodique.

On peut démontrer que si M n'est ni périodique ni décomposable, alors elle est *ergodique*.

Si toutes les lignes de \tilde{M} sont identiques, le système est complètement ergodique. Dans ce cas, pour un m suffisamment grand le système ne dépend que de l'état initial. C'est à dire ,

$$\lim_{m \rightarrow +\infty} P(m) = P(0). \lim_{m \rightarrow +\infty} M^m = P(0).\tilde{M} = \tilde{P}.$$

où \tilde{P} est le vecteur limite et l'une des lignes de \tilde{M} . On peut montrer que :

$$\tilde{P} = \tilde{P}.M \text{ et } \sum_{i=1}^n \tilde{P}_i.$$