



**HAL**  
open science

# Modélisation spatio-temporelle à base de modèles de Markov cachés pour la prévision des changements en imagerie satellitaire : cas de la végétation et de l'urbain

Houcine Essid

## ► To cite this version:

Houcine Essid. Modélisation spatio-temporelle à base de modèles de Markov cachés pour la prévision des changements en imagerie satellitaire : cas de la végétation et de l'urbain. Autre [cs.OH]. Université Blaise Pascal - Clermont-Ferrand II, 2012. Français. NNT : 2012CLF22317 . tel-01037990

**HAL Id: tel-01037990**

**<https://theses.hal.science/tel-01037990>**

Submitted on 23 Jul 2014

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

N° d'ordre: D. U: 2317  
EDSPIC: 598

**UNIVERSITE BLAISE PASCAL - CLERMONT II**

ECOLE DOCTORALE  
SCIENCES POUR L'INGENIEUR DE CLERMONT-FERRAND

**T h è s e**

Présentée par

**HOUCINE ESSID**

pour obtenir le grade de

**DOCTEUR D'UNIVERSITÉ**

**SPECIALITE : INFORMATIQUE**

**Modélisation spatio-temporelle à base de modèles de Markov cachés pour la  
prévision des changements en imagerie satellitaire :  
Cas de la végétation et de l'urbain**

Soutenue publiquement le 13 Décembre 2012 devant le jury :

M. Sami FAIZ  
M. Grégoire MERCIER  
M. Sami FAIZ  
M. Vincent BARRA  
M. Imed Riadh FARAH

Président  
Rapporteur et examinateur  
Rapporteur et examinateur  
Directeur de thèse  
Directeur de thèse

# Résumé

Les séries temporelles d'images satellitaires sont une source d'information importante pour le suivi des changements spatio-temporels des surfaces terrestres. En outre, le nombre d'images est en augmentation constante. Pour les exploiter pleinement, des outils dédiés au traitement automatique du contenu informationnel sont développés. Néanmoins ces techniques ne satisfont pas complètement les géographes qui exploitent pourtant, de plus en plus couramment, les données extraites des images dans leurs études afin de prédire le futur. Nous proposons dans cette thèse, une méthodologie générique à base d'un modèle de Markov caché pour l'analyse et la prédiction des changements sur une séquence d'images satellitaire. Cette méthodologie présente deux modules: un module de traitement intégrant les descripteurs et les algorithmes classiquement utilisés en interprétation d'images, et un module d'apprentissage basé sur les modèles de Markov cachés.

La performance de notre approche est évaluée par des essais d'interprétations des événements spatio-temporels effectuées sur plusieurs sites d'études. Les résultats obtenus permettront d'analyser et de prédire les changements issus des différentes séries temporelles d'images SPOT et LANDSAT pour l'observation des événements spatio-temporels telle que l'expansion urbaine et la déforestation.

**Mots clefs:** Télédétection, analyse spatio-temporelle, modèle de Markov caché, descripteurs d'images, imagerie satellitaire.

# Abstract

The time series of satellite images are an important source of information for monitoring spatiotemporal changes of land surfaces. Furthermore, the number of satellite images is increasing constantly, for taking full advantage, tools dedicated to the automatic processing of information content is developed. However these techniques do not completely satisfy the geographers who exploit more currently, the data extracted from the images in their studies to predict the future. In this research we propose a generic methodology based on a hidden Markov model for analyzing and predicting changes in a sequence of satellite images. The methodology that is proposed presents two modules: a processing module which incorporating descriptors and algorithms conventionally used in image interpretation and a learning module based on hidden Markov models.

The performance of the approach is evaluated by trials of interpretation of spatiotemporal events conducted in several study sites. Results obtained allow us to analyze and to predict changes from various time series of SPOT and LANDSAT images for observation of spatiotemporal events such as urban development and deforestation.

***Keywords*** Remote sensing, spatiotemporal analysis, hidden Markov model, image descriptors, satellite image.

# Dédicaces

*À Sidi,*

*Tous les mots du monde ne sauraient traduire l'immense amour que je te porte, ni la profonde gratitude que je te témoigne pour tous les efforts et les sacrifices que tu n'as jamais cessé de consentir pour mon instruction et mon bien-être.*

*Merci pour ton soutien durant les moments difficiles.*

*Que Dieu tout puissant te garde et te procure santé, bonheur et longue vie pour que tu demeures le flambeau illuminant notre chemin.*

*Ton petit frère Houcine*

# Remerciements

C'est avec profond bonheur que je saisis cette occasion solennelle, pour exprimer ma haute gratitude et mes sincères remerciements à mes directeurs de thèse: Monsieur Imed Riadh Farah, Maître de conférences à l'Université de la Manouba, et Monsieur Vincent Barra, Professeur à l'Université de Blaise Pascal à Clermont Ferrand II, qui ont su conduire mes recherches et m'accompagner tout au long de ces années en combinant, de façon subtile, les critiques et, dans les moments difficiles, les encouragements. Merci donc pour votre soutien sans faille, votre confiance et votre disponibilité.

Mes remerciements vont également aux membres du jury pour l'honneur qu'ils m'ont accordé en acceptant d'assister, lire et juger mon travail.

Je tiens à exprimer ma profonde reconnaissance à Monsieur Sami Faiz, Maître de conférences à l'Université de Jendouba, et Monsieur Grégoire Mercier, Professeur à l'Université Telecom Bretagne d'avoir accepté la fastidieuse tâche de rapporter ce travail. Je les remercie pour les remarques et les critiques qu'ils m'ont prodiguées et qui ont permis de perfectionner le présent manuscrit.

Je tiens à remercier Monsieur Khaled Mellouli professeur à l'IHEC de Carthage pour m'avoir donné la possibilité d'étudier la modélisation stochastique et pour m'avoir fait profiter de ses connaissances sur les réseaux Bayesiens.

Mes remerciements vont également à tous les membres de laboratoire RIADI-GDL en Tunisie et LIMOS en France et à tous ceux qui m'ont aidé et encouragé tout au long de cette thèse.

# Table des matières

Liste des figures

Liste des tableaux

<b>Introduction générale .....</b>	<b>1</b>
<b>Chapitre 1: Méthodes de détection et de prévisions des changements .....</b>	<b>5</b>
1. Introduction .....	5
2. Pré analyse en imagerie satellitaires .....	5
2.1. Acquisition, résolution et prétraitements d'une l'imagerie satellitaire .....	5
2.2. Réduction des primitives .....	7
3. Modélisation spatio-temporelle des images satellitaires .....	9
3.1. Identification des objets .....	9
3.1.1. Les traitements de bas niveau .....	9
3.1.2. Les traitements de niveau intermédiaire .....	10
3.1.3. Les traitements de haut niveau .....	10
3.2. Caractérisation des objets .....	10
3.2.1. Description liée à l'objet .....	10
3.2.2. Description liée à la scène .....	11
3.2.3. Typologie des relations spatiales .....	11
3.2.3.1. Méthodes de détection des relations spatiales .....	16
3.2.3.2. Les relations temporelles .....	19
3.2.3.3. Les relations spatio-temporelles .....	21
4. Les techniques de détection des changements .....	23
4.1. Méthode par transformation .....	23
4.2. Méthode algébrique .....	24
4.3. Méthode par classification .....	24

4.4. Méthode par analyse visuelle .....	24
4.5. Modèles avancés .....	25
5. Les techniques de prévision des changements .....	26
5.1. Les modèles mathématiques .....	27
5.2. Les modèles intelligents .....	27
5.3. Les modèles probabilistes .....	27
5.3.1. Les automates temporisés .....	28
5.3.2. Les modèles experts .....	28
5.3.3. Les réseaux Bayésiens .....	29
5.3.4. Les modèles de Markov cachés (MMC) .....	30
5.3.5. Typologie des MMC .....	31
5.3.5.1. MMC hiérarchique .....	32
5.3.5.2. MMC gaussien .....	33
5.3.5.3. MMC à temps continu .....	33
5.3.5.4. Le cas d'un MMC couplé .....	34
5.3.5.5. MMC triplet .....	35
6. Etat de l'art des systèmes de détection et de prévision des changements .....	36
7. Discussion et conclusion .....	36
<b>Chapitre 2 : Modélisation spatio-temporelle à base de MMC pour la prévision des</b>	<b>39</b>
<b>changements en imagerie satellitaire</b>	
1. Introduction .....	39
2. Modélisation spatio-temporelle à base de modèle de Markov caché .....	39
2.1. La phase d'apprentissage .....	40
2.2. La phase de suivi et de prévision .....	42
2.3. Modélisation spatio-temporelle des données .....	42
2.3.1. Extraction des objets .....	43

2.3.2. Extraction des vecteurs caractéristiques .....	44
3. Modèle de Markov caché hybride proposé .....	46
3.1. Notation .....	46
3.2. Estimation des paramètres du modèle .....	47
3.3 Techniques utilisées .....	50
4. Modèle de Markov Caché appliqué à la végétation et l'urbanisme .....	53
4.1. Formalisation du modèle au cas de la végétation .....	53
4.2. Formalisation du modèle au cas de l'urbain.....	55
5. Conclusion .....	61
<b>Chapitre 3 : Réalisations et résultats .....</b>	<b>62</b>
1. Introduction .....	62
2. Expérimentation générique .....	62
2.1. Source d'images .....	62
2.2. Traitement et Apprentissage des observations .....	63
2.3. Interprétation des événements spatio-temporels .....	63
2.4. Résultats expérimentaux .....	64
2.5. Expérimentation des données synthétiques .....	66
3. Expérimentation du cas des forêts .....	67
3.1. Environnement de développement .....	67
3.2. Source d'images .....	68
3.3. Traitement et apprentissage des observations .....	70
3.4. Interprétation des événements et résultats expérimentaux .....	71
4. Expérimentation du cas de l'urbain .....	72
4.1. Extraction du masque urbain .....	72
4.2. Segmentation et classification du masque urbain .....	73
4.3. Résultats expérimentaux .....	74
5. Conclusion .....	76

<b>Conclusion générale et Perspectives .....</b>	<b>78</b>
<b>Bibliographie .....</b>	<b>81</b>

# Liste des figures

Figure 1: Courbe de réflectance des végétaux, sols et eaux .....	6
Figure 2: Analyse en composantes principales .....	8
Figure 3: Composition colorée de plusieurs canaux ACP .....	8
Figure 4: Opérateurs élémentaires de mouvement .....	11
Figure 5: Division de l'espace suivant une projection et suivant de secteurs angulaires .....	12
Figure 6: Les relations directionnelles mixtes et strictes .....	12
Figure 7: Les huit relations topologiques .....	13
Figure 8: Illustration de la méthode de Kim et Um dans le cas d'un chevauchement .....	16
Figure 9: Confusion d'une disjonction avec un chevauchement .....	17
Figure 10: Exemple d'utilisation de la méthode de Walker et al. ....	17
Figure 11: Application de la méthode de Lee .....	19
Figure 12: Relations sur les intervalles temporels d'Allen .....	21
Figure 13: Modèle de chaîne de Markov ergodique .....	31
Figure 14: Modèle de Bakis à 3 états .....	31
Figure 15: Exemple de structure de modèle de Markov hiérarchique .....	33
Figure 16: Modèle de Markov caché en cas d'observations continues .....	34
Figure 17: Architecture globale du modèle .....	40
Figure 18: L'approche proposée pour l'apprentissage .....	42
Figure 19: Une chaîne de traitement d'une image satellite .....	45
Figure 20: Construction des observations .....	45
Figure 21: Schéma d'une carte de Kohonen connectée à un stimulus .....	50
Figure 22: Système d'analyse spatio-temporelle .....	52
Figure 23: Les traitements appliqués sur une image satellite .....	53
Figure 24: Structure du modèle de végétation .....	54
Figure 25: Un modèle de Markov caché couplé avec 2 chaînes .....	55
Figure 26: Suivi du masque urbain en 4 directions .....	58
Figure 27: Construction de la base de variation dans un MMCC .....	60
Figure 28: Module d'apprentissage dans le cas du MMCC .....	61
Figure 29: 4 séries temporelles d'images satellitaires du projet ADAM .....	62
Figure 30: Exemple d'interprétation des événements spatio-temporels .....	64
Figure 31: Extraction de la végétation en utilisant le NDVI .....	68

Figure 32: Extraction de la végétation en utilisant le RVI .....	<b>68</b>
Figure 33: Extraction de la végétation saine .....	<b>69</b>
Figure 34. Images SPOT de Grand Tunis en 1987 et 2001.....	<b>73</b>
Figure 35: Extraction du masque urbain .....	<b>73</b>
Figure 36: Segmentation et classification du masque urbain .....	<b>74</b>
Figure 37 : La variation des indices d'Haralick .....	<b>74</b>

# Liste des tableaux

Tableau n°1: Résolution des satellites d'observation .....	7
Tableau n°2: Définition formelle des huit relations primaires .....	14
Tableau n°3: Intersections des composantes de A et B pour chaque relation .....	15
Tableau n°4: Les correspondances entre poids et relation .....	18
Tableau n°5: Etude comparative entre le MMC Discret et le MMC Continu .....	30
Tableau n°6: Résultats des relations spatio-temporelles .....	59
Tableau n°7: Quelques vecteurs caractéristiques de la région R11 de la première séquence	63
Tableau n°8: Résultats expérimentaux de reconnaissances .....	65
Tableau n°9: Exemple de résultats d'interprétation .....	65
Tableau n°10: Exemple de résultats de prévision de la région R11 .....	65
Tableau n°11: Les résultats des données synthétiques .....	66
Tableau n°12: Calcul de la surface de végétation normale et saine .....	70
Tableau n°13: Calcul de la vitesse de variation de la végétation normale et saine .....	70
Tableau n°14: Définition des états cachés .....	70
Tableau n°15: Exemple de couplage de descripteurs .....	76

# Introduction générale

L'évolution générale des capteurs satellitaires a permis, ces dernières décennies, d'observer régulièrement une scène avec des données de plus en plus précises et sophistiquées. Les séries temporelles d'images satellitaires (STIS) se présentent comme le fruit et la progression de l'imagerie de télédétection classique.

Analogiquement aux méthodes de vision par ordinateur, le domaine de l'imagerie multi et hyper spectrale mesure, analyse et interprète les spectres. Ce fort potentiel a conforté l'émergence de récentes applications de télédétection, telles que :

- l'agriculture de précision : le suivi à une échelle locale permet le dépistage précoce des maladies, emploi adapté des engrais etc. ;
- la géologie et l'étude des sols : regroupant la minéralogie, la lithologie, l'exploration minière, la volcanologie, etc. ;
- l'environnement et l'écologie terrestre : concernant la cartographie de l'occupation des sols, l'écologie côtière, la gestion des ressources, etc. ;
- l'océanographie : incluant la bathymétrie, etc. ;
- la croissance urbaine : c'est un phénomène qui caractérise la majorité des aires métropolitaines mondiales. Elle est associée à la substitution et à la fragmentation des habitats naturels et des zones agricoles par le développement des infrastructures en zones résidentielles ou commerciales ;
- le domaine militaire : générant des cartographies de terrains, la détection de cibles, etc.

La richesse de l'information mesurée par ces systèmes requiert des concepts mathématiques évolués pour supporter les efforts d'interprétation et mener au mieux les applications précitées. Conjointement à cela, avec l'émergence des images multi-temporelles, l'analyse et l'interprétation de signaux dépendant de plusieurs facteurs (le temps, la réflectance, les longueurs d'onde, etc.) s'est démocratisé. Cependant, la quantité d'informations acquises sur une base quotidienne ou mensuelle reste largement sous-exploitée. Le développement de nouvelles méthodes d'analyses d'images est donc, primordial pour l'exploitation de cette masse des données disponibles. Le développement de méthodes efficaces pour l'analyse de ces changements est l'une des questions de recherche, à la fois pertinentes et ouvertes, à laquelle la communauté de télédétection doit faire face.

D'autre part, la composante temporelle reste peu intégrée dans ces travaux, même si elle est également, largement utilisée pour analyser la dynamique d'objets géographiques. Cependant, une fois rajoutée aux dimensions spectrale et spatiale, elle présente une précieuse source d'information qui, si elle est judicieusement exploitée, permet de mieux suivre et reconnaître les objets difficiles à

discriminer à partir d'une seule image. Toutefois, l'utilisation de cette composante augmente la complexité habituellement associée au traitement des images mono-dates de télédétection. Le traitement et l'analyse des STIS nécessitent des développements méthodologiques particuliers qui prennent en compte la comparabilité des images d'une date à l'autre et les contraintes temporelles liées au processus ou au phénomène observés. En outre, ces systèmes méthodologiques devraient résoudre le problème de l'explication et de la prédiction des événements spatio-temporels à partir des STIS qui permettent de quantifier les incertitudes et de fournir une aide à la décision crédible.

De nos jours, la modélisation et l'interprétation des images est un axe de recherche en pleine expansion où se fédèrent des méthodes issues de l'intelligence artificielle, de la théorie de l'information, de l'analyse de données traditionnelles et surtout des méthodes de modélisation probabilistes et statistiques tels que les modèles de Markov cachés (HMM pour Hidden Markov Models). Ces outils de modélisation sont aussi dits descriptifs ou exploratoires. Les méthodes descriptives visent à mettre en évidence des informations cachées. Quant aux méthodes dites prédictives ou explicatives, elles visent à extrapoler de nouvelles informations à partir des données existantes. Dans le cas de la télédétection, l'information est obtenue par l'acquisition simultanée des données, sur plusieurs centaines de canaux spectraux contigus, qui génèrent des spectres de réflectivité pour chaque pixel de l'image.

Dans cette thèse, nous abordons les modèles prédictifs sous l'angle de la modélisation stochastique des données des séries temporelles d'images. Il s'agit de cerner l'incertain en modélisant la variabilité d'un phénomène qui n'est pas encore totalement explicable, afin de faire apparaître des curiosités statistiques susceptibles de contenir des informations et des descripteurs de différentes natures. Ces changements peuvent être de nature très différente et provenir de phénomènes brutaux ou lents. Les changements ponctuels qui surviennent de manière brutale tels que les incendies, les inondations ou les éruptions volcaniques, sont généralement lourds de conséquences tant sur le plan humain que sur l'écosystème. Leur détection est alors essentielle pour la gestion des risques et des situations de crise. D'autres types de changements se manifestent sur des périodes plus longues (décadaires, annuelles ou décennales) de manière continue. Leur détection est alors nécessaire dans le cadre des processus de suivi et de contrôle de la surface, aussi bien pour les applications de géographie ou de biophysique que pour les applications liées aux interactions entre la surface et l'atmosphère, et ce, afin de participer à la protection de l'environnement. L'avantage d'une telle approche est de fournir une nouvelle description des données qui peut différer de celle proposée dans la littérature. Par conséquent, de nouvelles caractéristiques peuvent ainsi être révélées.

Les travaux effectués dans le cadre de cette thèse portent sur le suivi de l'évolution d'un objet au cours du temps. Dans ce contexte, l'étude vise à proposer une nouvelle approche d'analyse et de détection de changements à partir d'une série d'images satellitaires acquises à des dates différentes pour une même scène. Ce qui permettra ensuite, de modéliser et d'interpréter les variations pour

pouvoir prédire les changements futurs. Pour accomplir cet objectif, nous nous plaçons dans le cadre de deux domaines ; l'extraction d'information à partir des données brutes, et l'analyse stochastique. Concernant l'extraction d'information, nous nous appuyons sur les outils de traitement d'images et les différents descripteurs d'une image satellitaire. Tandis que pour la modélisation stochastique, les processus markoviens possèdent toutes les qualités pour représenter de manière générique la dynamique d'objets à partir d'une séquence d'images. Le but de cette méthodologie est la détection, le suivi et la modélisation des changements d'un objet à partir d'une série d'images satellitaires multi-dates en intégrant d'autres descripteurs spécifiques à chaque domaine étudié. L'adaptation des modèles de Markov cachés selon le domaine d'étude permettra enfin de prédire les variations futures.

Le manuscrit de thèse est composé d'une introduction générale, de trois chapitres et d'une conclusion générale :

Dans l'introduction, nous exposons le contexte et la problématique de ce travail de thèse pour l'analyse spatio-temporelle des séries temporelles d'images satellitaires. Les motivations de ce travail ont été aussi abordées par rapport à la littérature ainsi que les principales étapes d'un système de modélisation, de détection et de prévision des changements.

Dans le premier chapitre, nous présentons un aperçu du domaine de l'analyse spatio-temporelle des données de télédétection, les différents concepts de base liés aux images satellitaires sont détaillés. Nous introduisons les assises fondamentales de la télédétection et les techniques d'identification et de description des objets. Ensuite, nous décrivons les méthodes de détection et de prévisions des changements à travers une revue de la littérature. Finalement, nous présentons les différents systèmes de prévisions et nous terminons par une discussion pour justifier nos choix.

Le deuxième chapitre est consacré à la présentation de notre approche proposée exploitant les séries temporelles d'images satellite, en coopération avec les techniques d'extraction d'informations, pour l'analyse spatio-temporelle à base d'un modèle markovien caché. L'architecture de l'approche proposée est décrite ainsi que les paramètres universels à ajuster et les descripteurs spécifiques à déterminer selon le domaine d'application. Nous rappelons aussi les propriétés et les définitions nécessaires à la mise en œuvre des chaînes de Markov cachées, qui constitue le cœur de notre travail de recherche. L'originalité principale de notre étude porte sur deux points principaux:

- L'utilisation des modèles de Markov cachés pour la modélisation et la prévision des changements. Ce modèle est couramment utilisé pour la résolution de problèmes de segmentation d'image, car la variable cachée peut représenter une classification, considérée alors comme solution du problème de

segmentation. En revanche, dans le cas des problèmes de prévision, plus complexes, où les données ne sont pas nécessairement des images, l'utilisation de ce modèle est, à notre connaissance, originale.

- Nous avons considéré le modèle de Markov caché comme une régularisation du problème et non plus comme solution. Nous avons choisi, pour tous les problèmes traités, de calculer l'estimateur de la moyenne a posteriori par un algorithme d'échantillonnage de Baum Welch, méthode qui nous semble particulièrement adaptée à l'utilisation des modèles de Markov cachés et applicable dans le cas de problèmes de prévision. Nous avons appliqué l'approche proposée sur divers données satellitaires et dans divers conditions. Ceci nous permet de montrer la généralité de notre approche en particulier ceux de prévision. La difficulté majeure restant l'échantillonnage d'une loi de probabilité non nécessairement gaussienne et dépendant du caractère non linéaire du problème.

Le troisième chapitre présente la réalisation de notre système méthodologique. Nous détaillons une analyse de performances sur trois sites d'études en utilisant différentes séries temporelles d'images SPOT et LANDSAT. La première expérimentation est générique. La deuxième s'intéresse à la déforestation. La dernière application concerne la détection des changements dans les zones urbaines. Enfin le modèle est utilisé pour la prédiction des variations futures de toute zone similaire aux zones d'apprentissage du modèle. Nous avons réalisé une plate forme pour l'extraction d'une région (forêt et urbaine) dans une image satellitaire, la détection des changements à travers une série temporelle d'images et l'apprentissage d'un MMC pour la prévision de l'état futur de cette région. L'évaluation du modèle a fournit des résultats satisfaisantes avec un taux d'erreur acceptable.

Enfin la conclusion présente une synthèse des travaux dont nous dégagons des perspectives pour la poursuite de ces travaux sur un plan théorique et applicatif.

# Méthodes de détection et de prévisions des changements

## 1. Introduction

Ce chapitre présente les différents concepts de base liés aux images satellitaires. Nous introduisons au début les principes de la télédétection. Ensuite nous présentons les techniques d'identification et de description des objets. Finalement, nous présentons les principales méthodes de détection et de prévisions des changements. Le lecteur intéressé pourra se référer à [1] pour plus de détails.

## 2. Pré-analyse en imagerie satellitaire

Les images satellitaires sont une source d'information importante pour le suivi des changements spatio-temporels des grandes surfaces. Ces images sont exploitées dans plusieurs domaines comme la géologie, l'archéologie, l'environnement, la surveillance maritime, la surveillance militaire, les études urbaines, etc. Chacun de ces domaines a ses propres besoins en données, traitement et analyse de l'information.

### 2.1. Acquisition, résolution et prétraitements d'images satellitaires

L'acquisition d'images constitue un maillon essentiel dans la chaîne de conception et de production d'images. Pour pouvoir manipuler une image sur un système informatique, il est avant tout nécessaire de lui faire subir une transformation qui la rendra lisible et manipulable par ce système. Le passage de cet objet externe (l'image d'origine) à sa représentation interne (dans l'unité de traitement) se fait grâce à une procédure de numérisation. Les capteurs satellites mesurent et quantifient l'énergie reçue. L'information ainsi véhiculée dépend de l'origine du rayonnement. On peut citer la réflexion de la lumière solaire pour les capteurs optiques, la rétro-réflexion d'un signal émis artificiellement pour le radar ou l'émission naturelle de la terre ou des objets observés pour l'infrarouge thermique. Les images sont délivrées sous forme raster, et à chaque pixel est associé une ou plusieurs valeurs numériques, en fonction du nombre de bandes du capteur. Chaque objet émet de l'énergie électromagnétique à cause de l'agitation des particules chargées qui sont présentes dans toute matière. Cette énergie est émise par les objets, mais elle peut aussi être transmise, absorbée et réfléchi par ces mêmes objets. L'analyse et l'interprétation des images de télédétection se fait en fonction du comportement spectral qui est le produit de l'interaction du

rayonnement et de l'objet à traiter. Les objets pouvant être traités par la télédétection sont divers (voir la figure 1).

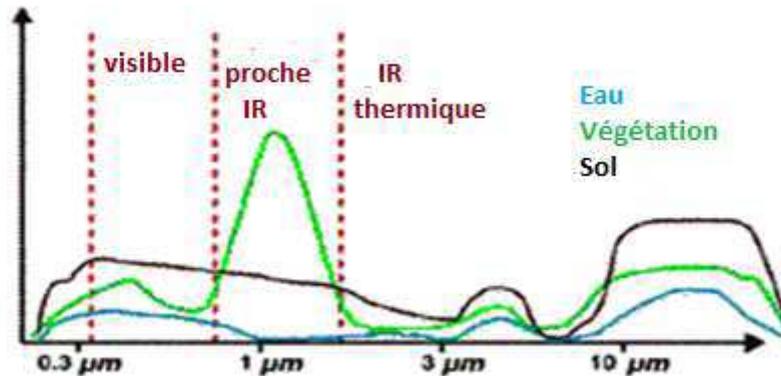


Figure 1. Courbe de réflectance des végétaux, sols et eaux [2]

Les caractéristiques fondamentales des images de télédétection sont la résolution spectrale, la résolution spatiale et la résolution temporelle. La résolution spectrale est l'aptitude du capteur à distinguer des rayonnements électromagnétiques de fréquences différentes. Plus le capteur est sensible à des différences spectrales fines (intervalles de longueur d'onde étroits), plus la résolution spectrale du capteur est élevée.

La résolution spatiale des images numériques est définie par le nombre de pixels par millimètres. Chaque élément, sensible du capteur haute résolution du satellite SPOT ne mesure que 13  $\mu\text{m}$  (0,013 mm) mais, cet élément représente une zone d'environ 10x10 mètres à la surface de la terre à travers le télescope du système d'observation. On dira donc que la résolution de ce capteur est de 10 mètres. Comme le capteur de ce satellite est composé de 6000 éléments sensibles placés le long d'une barrette, le satellite circulant sur son orbite balaye une zone de 6000 x 10 m (60km) à la surface de la terre. Les résolutions des satellites d'observation de la terre les plus courantes sont données dans le tableau 1.

Satellite	Capteur	Résolution-sol
EO-1	Omega	350m
Landsat	MSS	80m
Landsat	Thematic Mapper	30m
EO-1	hyperion	30m
SPOT	XS (Multispectral)	20m
SPOT	Panchromatique	10m
Ikonos	Multispectral	4m
Ikonos	Panchromatique	1m

Tableau 1. Résolution des satellites d'observation

La résolution temporelle est définie par la période de révolution d'un satellite. En effet, la fauchée des capteurs embarqués permet d'observer la surface terrestre avec une fréquence temporelle de mensuelle (exemple : 26 jours pour SPOT/HRV) à journalière (exemple : SPOT/VGT). Les images acquises peuvent subir des corrections géométriques, radiométriques et atmosphériques. Les filtrages sont aussi des opérations destinées à améliorer la lisibilité des images et/ou d'en extraire certaines informations [3] [4].

## 2.2. Réduction des primitives

Les prétraitements incluent toutes les fonctions effectuées avant la segmentation et l'extraction de caractéristiques pour produire une version exploitable de l'image d'origine afin qu'elle puisse être utilisée directement et efficacement. Mais, vu le grand volume d'information lu, à partir d'une image satellitaire, le nombre de bandes doit parfois être réduit. Les méthodes de réduction de primitives sont particulièrement adaptées aux primitives représentées sous forme de vecteurs de dimension finie  $m$ . Le but des méthodes de réduction de dimensionnalité consiste à transformer l'espace des primitives en un espace de dimension plus petite  $k < m$ , tout en conservant au maximum l'information [5]. L'Analyse en Composantes Principales (ACP) [6] est une méthode de la famille de l'analyse des données et plus généralement de la statistique multi variée, qui consiste à transformer des variables liées entre elles (dites "corrélées" en statistique) en des nouvelles variables indépendantes les unes des autres (donc "non corrélées"). Ces nouvelles variables sont nommées "composantes principales". L'ACP permet au praticien de réduire l'information en un nombre de composantes plus limité que le nombre initial de variables [7]. Les images d'une même scène enregistrées suivant les différentes bandes spectrales du capteur sont hautement corrélées [8]. Compte tenu de la redondance d'informations à traiter, on peut utiliser l'ACP pour condenser les données originelles en de nouveaux groupements de façon à ce qu'elles ne présentent pas de corrélation entre eux et soient ordonnées en terme de pourcentage de variance apportée par chaque composante. Ainsi, la première composante principale contient les informations relatives

à la variance maximale, la deuxième contient les informations relatives à la variance suivante. Le processus est répété jusqu'à l'obtention de la  $n^{\text{ième}}$  et dernière composante principale. Les pertes d'informations diminuent d'une étape à la suivante. En général on obtient facilement 95% voir plus avec très peu de composantes au final.

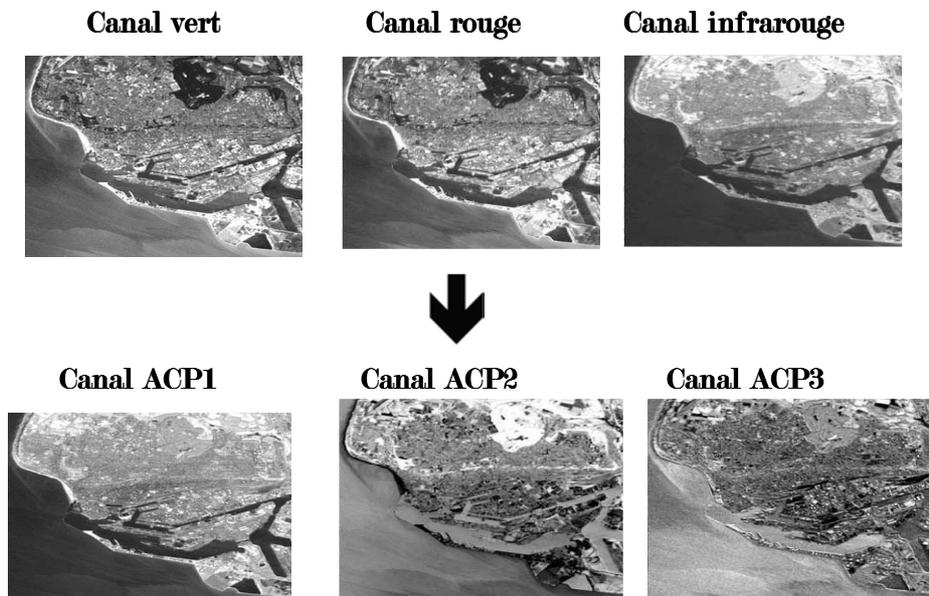


Figure 2. Analyse en composantes principales [9]

Dans l'exemple de la figure 2, l'ACP a porté sur les canaux vert, rouge et proche-infrarouge d'une image SPOT, pour générer les trois canaux 1, 2 et 3 :

- le premier canal montre la brillance globale de l'image et améliore les contrastes. Ce canal est riche sur le plan sémantique ce qui représente le maximum d'information sur l'image.
- Le deuxième, résume les différences spectrales fondamentales entre les canaux sources. Il est adapté à l'étude de la végétation.
- Le troisième est constitué du bruit résiduel, et ne présente que rarement de l'intérêt.

Le codage RVB = ACP1 / ACP2 / ACP3 donne la figure 3.



Figure 3. Composition colorée de plusieurs canaux ACP

Suite à la réduction des primitives (si elle est nécessaire) selon le domaine d'application, nous passons à l'identification et la description spatio-temporelles des objets.

### **3. Modélisation spatio-temporelle des images satellitaires**

Dans cette section, nous allons détailler les méthodes d'identification et de description spatio-temporelles des objets.

#### **3.1. Identification des objets**

Dans la littérature, il existe de nombreuses méthodes de segmentation [10]. Les différentes techniques ont leurs avantages et leurs limites. Leur utilisation dépend généralement, du problème à résoudre ; le but est donc de trouver la méthode la plus adaptée à une famille d'applications donnée. L'enjeu de ces travaux est de rechercher une stratégie de segmentation robuste, permettant ainsi de traiter le plus grand nombre de situations possibles. Nous pouvons ainsi classer les méthodes de segmentation d'images selon trois niveaux :

- Bas niveau: traitements qui mettent en évidence les caractéristiques essentielles de l'image.
- Niveau intermédiaire: extraction d'éléments structurants de l'image comme les segments.
- Haut niveau: utilisation du contexte et du rapport entre les éléments structurant.

##### **3.1.1. Les traitements de bas niveau**

Les traitements de bas niveaux font apparaître les caractéristiques qui nous intéressent dans l'image. Pour en extraire les éléments nous pourrions utiliser des traitements de plus haut niveau. La description ci-dessous n'est évidemment pas exhaustive. Elle présente les algorithmes intéressants pour l'analyse d'images satellites à très haute résolution. Pour analyser une image automatiquement, il est souhaitable de réduire la quantité d'informations pour limiter le temps de calcul, tout en gardant l'information pertinente de l'image. La méthode qui est utilisée fréquemment pour répondre à ce problème est la segmentation. Celle-ci consiste en une extraction des indices visuels de l'image. La segmentation commence en général par l'utilisation d'un des deux traitements : la détection de région ou la détection de contour [11].

###### **- Détection région**

Cette première approche de segmentation est la partition en zones homogènes constituées de pixels qui vérifient un critère (à définir), lequel n'est pas vérifié par les pixels des régions voisines. Il existe deux familles de méthodes pour faire une extraction de région. L'algorithme Split and Merge et l'algorithme d'accroissement de région [12].

### - **Détection de contour**

La recherche des contours dans une image numérique est un des problèmes les plus étudiés depuis l'origine des travaux sur l'imagerie numérique. Les contours sont les lieux de variations significatives de l'information. Une variation existera si le module du gradient est localement maximum ou si la dérivée seconde présente un passage par zéro. Pour extraire les contours caractéristiques de l'image, il existe de nombreuses méthodes qui recherchent le meilleur compromis entre la sensibilité au bruit et la bonne localisation des contours [13].

#### **3.1.2. Les traitements de niveau intermédiaire**

Il s'agit essentiellement de la segmentation. Celle-ci se fait en deux parties : la recherche des variations des contours, puis à partir de cette carte de variations, on fait une extraction des éléments essentiels (segments, arcs ...) de l'image. Les méthodes de niveau intermédiaire s'intéressent à cette extraction. Les éléments de cette extraction seront ensuite regroupés ou sélectionnés pour reconstruire les objets de la scène [14].

#### **3.1.3. Les traitements de haut niveau**

Ces méthodes sont utilisées pour trier, regrouper ou sélectionner les éléments de base qui ont été extraits avec les outils de bas niveaux. Dans cette étape, il faut faire des choix en fonction du contexte et des éléments de l'image que l'on souhaite extraire. Pour les bâtiments par exemple, on pourra utiliser la relation entre le toit et l'ombre, la forme rectangulaire, la différence de luminosité du toit par rapport au sol, la taille du bâtiment etc. Il est difficile de déterminer une méthode générique de haut niveau pour extraire les éléments de l'image satellitaire à très haute résolution. Pour chaque type d'images et chaque type d'éléments à extraire, il faut le plus souvent déterminer une méthode spécifique.

### **3.2. Caractérisation des objets**

Après avoir segmenté la série des images satellitaires, nous procédons à la lecture des mesures décrivant chaque objet. En effet, l'évolution de l'objet au cours du temps est déterminée par l'évolution de ces mesures. Il existe deux types de descriptions d'objets. La première est liée à l'objet et la deuxième est liée à la scène.

#### **3.2.1. Description liée à l'objet**

Au cours des années 1990-2000 de nombreux travaux ont tenté [15] [16] d'approcher certaines formalisations des représentations disponibles pour restituer les processus spatio-temporels. Géographes et cartographes se sont également intéressés, plus récemment, à ces questions. Trois

concepts semblent suffisants pour caractériser le changement spatial lorsqu'il affecte des objets délimités [17], vie d'un objet [18], mouvement et changement de forme (voir figure 4) [19] [20] et la généalogie d'un objet qui est formée par la succession structurée des objets antérieurs qui ont contribué à le construire ; c'est par exemple le cas d'une parcelle cadastrale qui peut résulter d'une séquence de divisions et regroupements partiels de parcelles antérieures. Deux concepts fondamentaux structurent cette notion de généalogie: ceux de fusion et d'éclatement. Les principaux descripteurs de l'image satellite sont classés en trois catégories, chacune représentant un type d'information : la radiométrie, la texture et la géométrie.

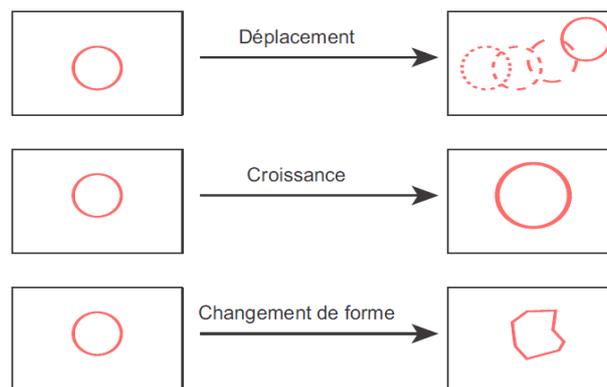


Figure 4. Opérateurs élémentaires de mouvement

### 3.2.2. Description liée à la scène

Une relation spatiale indique comment un certain objet est situé dans l'espace par rapport à un certain objet de référence. Puisque l'objet de référence est habituellement beaucoup plus grand que l'objet pour lequel on place, le dernier est souvent représenté par un point. L'objet de référence est souvent représenté par une boîte (oblique ou axe-parallèle).

### 3.2.3. Typologie des relations spatiales

Trois classes de relations spatiales sont victimes de discrimination qui sont fondées sur différents concepts spatiaux qui sont définies par Egenhofer. Il semble naturel pour chaque classe de développer un formalisme indépendant décrivant les relations [21] :

- **Les relations topologiques**: sont invariantes par transformations topologiques, comme la translation, l'échelle et la rotation. Des exemples sont des termes comme *voisin* et *disjoints*.
- **Les relations de direction**: s'appuient sur la définition de l'ordre de commande et stricte, respectivement. En général, chaque relation d'ordre a une relation inverse. Par exemple, *derrière*, est une relation d'ordre spatial basé sur l'ordre de la *préférence* avec la relation inverse *en face de*.
- **Les relations métriques**[22]: exploiter l'existence de mesures, telles que distances et les directions. Par exemple, "à moins de 5 miles de la l'autoroute I 95 » décrit un couloir spécifique

basée sur une distance. Ces relations se basent sur la notion de distance dans un espace euclidien. La distance entre deux points est donnée par la formule :

$$d_{a-b} = \sqrt{(xa - xb)^2 + (ya - yb)^2 + (za - zb)^2} \quad (\text{Eq. 1})$$

Ces relations sont assez simples à gérer pour deux points, elles se compliquent pour des objets plus complexes. De nombreux outils mathématiques sont à disposition pour les gérer, pour autant que les coordonnées euclidiennes des points constitutifs soient connues. Les relations ordinales quant à elles possèdent leur propre modélisation. Frank [23] définit par exemple une représentation basée sur des relations cardinales avec un ensemble de symboles définissant les valeurs que peuvent prendre les relations, un ensemble d'opérations applicables à ces relations et enfin un ensemble d'axiomes définissant les résultats des opérations. Il propose également plusieurs découpages de l'espace pour établir ses relations (voir figure 5).

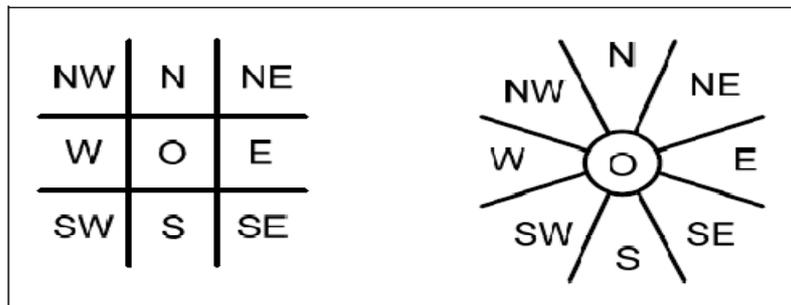


Figure 5. Division de l'espace suivant une projection et suivant des secteurs angulaires

Les relations directionnelles représentent les positions des objets les uns par rapport aux autres, ou bien par rapport au cadre de l'image, de la même manière que l'on exprime des directions géographiques par rapport aux quatre points cardinaux. En effet, il existe principalement trois types de relations directionnelles :

- *strictes* : Nord, Sud, Est et Ouest.
- *mixtes* : idem + Nord-Est, Nord-Ouest, Sud-Est et Sud-Ouest.
- *de position* : à droite, à gauche, au-dessus et en-dessous.

Ces relations sont décrites dans la figure 6.

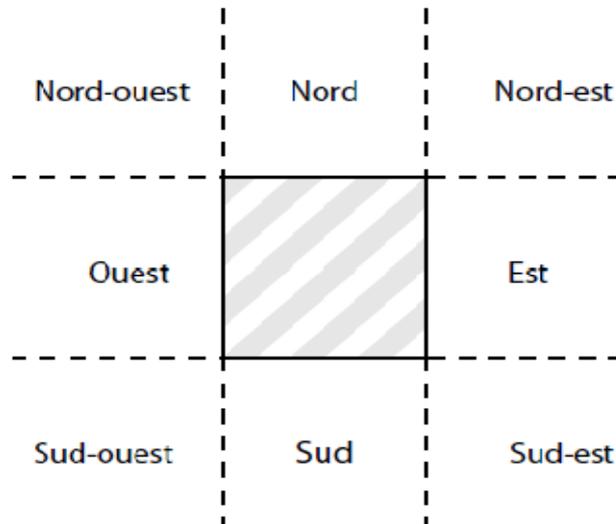


Figure 6. Les relations directionnelles mixtes et strictes

Concernant les relations topologiques, elles n'indiquent pas le positionnement cardinal des objets, mais plutôt l'interaction entre deux objets, c'est à dire la manière dont un objet recouvre partiellement ou totalement un autre objet. Un premier modèle baptisé « modèle des quatre intersections » [24] a été proposé par M. J. Egenhofer. Il a ensuite été étendu à un modèle à neuf intersections [25] [26]. Ce modèle a servi de base à des études sur toutes les relations possibles entre différents types d'objets complexes. L'étude citée de M. Schneider [27] est la plus complète qui soit disponible sur les relations spatiales. Elle a permis de mettre en évidence les huit relations primaires qui sont détaillées dans la figure 7. Quatre de ces relations ont été regroupées par paires car ce sont des relations symétriques.

Il convient d'apporter une précision sur les deux couples de relations *couvre/est recouvert* par *et contient/est à l'intérieur de*. Ces deux paires de relations sont très semblables, comme le montre la figure 8. La différence réside uniquement dans le fait que pour la paire *couvre/est recouvert par*, les contours des deux objets ont une partie commune, alors que pour la paire *contient/est à l'intérieur de*, les deux contours sont complètement disjoints.

Les autres relations sont suffisamment triviales pour se passer d'explication.

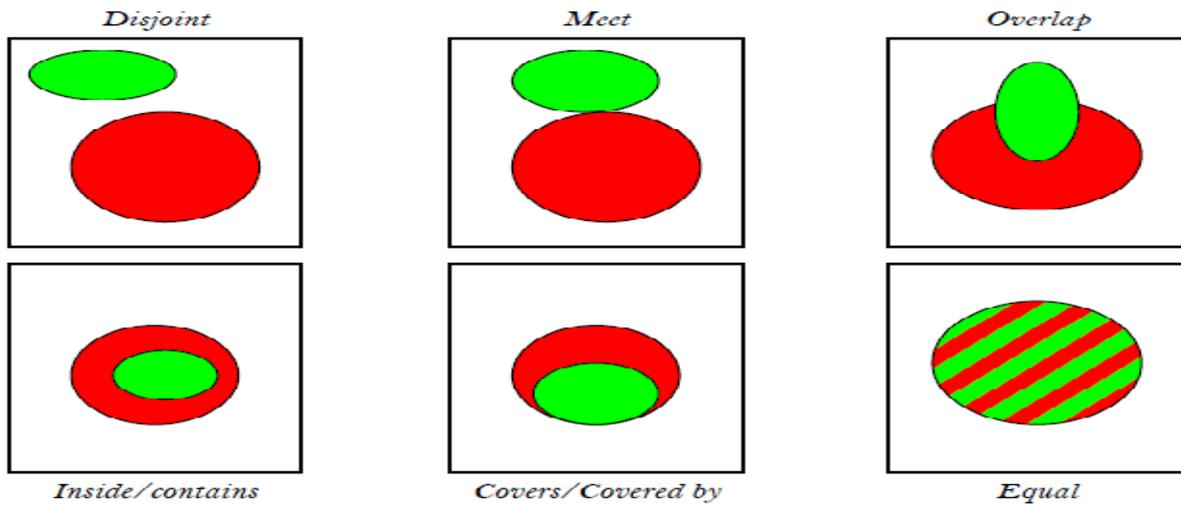


Figure 7. Les huit relations topologiques

Les relations décrites dans cette figure portent leurs noms anglais d'origine. En voici une traduction : « *Disjoint* » : disjoint, « *contains* » : contient, « *Meet* » : touche, « *Covers* » : couvre, « *Overlap* » : chevauche, « *covered by* » : est recouvert par, « *Inside* » : est à l'intérieur de, « *Equal* » : égal

Chacune des huit relations primaires a été formellement définie par M. Schneider et T. Behr [27] de la manière suivante : Soit un objet A. On pose les notations,

Notation 1 :  $\partial A$  représente le contour de A.

Notation 2 :  $A^\circ$  représente l'intérieur de A.

Notation 3 :  $A^-$  représente l'extérieur de A.

En étendant ces notations à un objet B, on peut définir ainsi les huit relations primaires possibles entre A et B :

Relation	Formulation Mathématique
<b>Disjoint(A, B)</b>	$A^\circ \cap B^- = \emptyset \wedge A^- \cap \partial B = \emptyset \wedge \partial A \cap B^- = \emptyset \wedge \partial A \cap \partial B = \emptyset$
<b>Meet(A,B)</b>	$A^\circ \cap B^- = \emptyset \wedge (A^- \cap \partial B \neq \emptyset \vee \partial A \cap B^- \neq \emptyset \vee \partial A \cap \partial B \neq \emptyset)$
<b>Inside(A,B)</b>	$A^\circ \cap B^- \neq \emptyset \wedge A^- \cap B^- = \emptyset \wedge A^- \cap B^- = \emptyset \wedge \partial A \cap \partial B = \emptyset$
<b>Contains(A,B)</b>	$A^\circ \cap B^- \neq \emptyset \wedge A^- \cap B^- = \emptyset \wedge A^- \cap B^- = \emptyset \wedge \partial A \cap \partial B = \emptyset$
<b>CoveredBy(A,B)</b>	$A^\circ \cap B^- \neq \emptyset \wedge A^- \cap B^- = \emptyset \wedge A^- \cap B^- = \emptyset \wedge \partial A \cap \partial B \neq \emptyset$
<b>Covers(A,B)</b>	$A^\circ \cap B^- \neq \emptyset \wedge A^- \cap B^- = \emptyset \wedge A^- \cap B^- = \emptyset \wedge \partial A \cap \partial B \neq \emptyset$
<b>Equal(A,B)</b>	$A^\circ \cap \partial B = \emptyset \wedge A^- \cap B^- = \emptyset \wedge \partial A \cap B^- = \emptyset \wedge \partial A \cap B^- = \emptyset \wedge A^- \cap B^- = \emptyset \wedge A^- \cap \partial B = \emptyset$
<b>Overlap(A,B)</b>	$A^\circ \cap B^- \neq \emptyset \wedge A^- \cap B^- \neq \emptyset \wedge A^- \cap B^- \neq \emptyset$

Tableau 2. Définition formelles des huit relations primaires

Pour transposer ces définitions sous forme d'algorithmes, on peut commencer par les synthétiser sous la forme d'un tableau représentant la valeur des intersections de chacune des composantes de

l'objet A (l'extérieur, l'intérieur et le contour) avec les composantes de l'objet B. C'est ce qui est fait dans le tableau 3.

	$\partial A$	$A^\circ$	$A^-$	
<b>disjoint(A,B)</b>	$\partial B$	0	0	-
	$B^\circ$	0	0	-
	$B^-$	-	-	-
<b>meet(A,B)</b>	$\partial B$	1	-	-
	$B^\circ$	-	0	-
	$B^-$	-	-	-
<b>inside(A,B)</b>	$\partial B$	0	-	-
	$B^\circ$	-	1	1
	$B^-$	-	0	-
<b>contains(A,B)</b>	$\partial B$	0	-	-
	$B^\circ$	-	1	0
	$B^-$	-	1	-
<b>coveredBy(A,B)</b>	$\partial B$	1	-	-
	$B^\circ$	-	1	1
	$B^-$	-	0	-
<b>covers(A,B)</b>	$\partial B$	1	-	-
	$B^\circ$	-	1	0
	$B^-$	-	1	-
<b>equal(A,B)</b>	$\partial B$	-	0	0
	$B^\circ$	0	-	0
	$B^-$	0	0	-
<b>overlap(A,B)</b>	$\partial B$	-	-	-
	$B^\circ$	-	1	1
	$B^-$	-	1	-

Tableau 3. Intersections des composantes de A et B pour chaque relation

Un "0" dans une cellule signifie que l'intersection doit être vide, un "1" signifie qu'elle doit être non vide, et un tiret indique qu'elle peut être quelconque.

### 3.2.3.1. Méthodes de détection des relations spatiales

Plusieurs techniques ont été utilisées pour la détection des relations spatiales entre objets présents dans une image, notamment la méthode de Kim et Um [28], la méthode de Walker [29] et la méthode de Lee [30]. Nous allons présenter pour chaque technique ses caractéristiques et ses limites.

#### a) Méthode de Kim et Um

Kim et Um [28] ont proposé en 1999 une des premières méthodes de détection des relations spatiales automatisée. Cette méthode s'appuie sur des objets de type vectoriels. La particularité de ces objets est qu'ils sont connus entièrement. Ainsi, les parties d'un objet A (par exemple) qui seraient cachées par un objet B, sont tout de même présentes dans l'image. Cela reprend la manière de travailler de certains logiciels de retouche d'images qui utilisent des calques vectoriels. Chaque objet est contenu sur un calque différent, ce qui permet de récupérer séparément les objets de l'image. La notion de calque reste une métaphore puisqu'il s'agit en réalité d'une structure de données plus complexe, mais le principe est le même : chaque objet est défini séparément des autres, et dans sa globalité. Cette approche suppose une détection manuelle des objets au préalable. Les auteurs utilisent l'approximation du plus petit rectangle englobant (*minimum bounding rectangle*) de sorte que chaque objet est remplacé par le plus petit rectangle qui le contient. Les opérations géométriques sont ensuite effectuées directement sur les rectangles associés à chaque objet. Ces opérations consistent à comparer les abscisses et les ordonnées des côtés des rectangles et d'inférer des relations spatiales. Dans l'exemple de la figure 8, on compare les bornes min et max en hauteur et en largeur des objets A et B. Ici, nous avons  $\min Y(B) < \min Y(A) < \max Y(A) < \max Y(B)$ . Nous en déduisons que la bande horizontale contenant A est contenue dans la bande horizontale contenant B. De plus, nous avons aussi  $\min X(A) < \min X(B) < \max X(A) < \max X(B)$ , ce qui signifie que les deux bandes verticales contenant A et B se chevauchent. De ces deux relations, nous pouvons conclure qu'il s'agit d'un chevauchement.

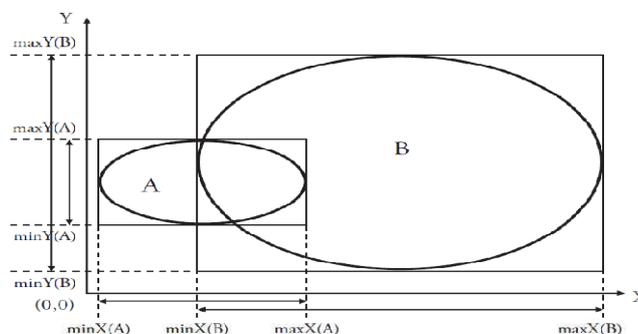


Figure 8. Illustration de la méthode de Kim et Um dans le cas d'un chevauchement

Cette méthode possède des limites suivant:

- L'approximation du plus petit rectangle englobant est source de beaucoup d'erreurs de jugement. Par exemple, dans la figure 9, nous avons exactement les mêmes relations d'ordre que dans la figure 8, sans pour autant avoir la même relation : dans le cas de la figure 8, il s'agit d'un chevauchement alors que dans le cas de la figure 9 les deux objets sont disjoints.
- Ce modèle pose aussi des problèmes pour la définition des relations *touche* et *couvre/est recouvert par*. On comprend facilement que le fait d'avoir une borne commune n'est pas une condition suffisante pour justifier d'avoir un contour commun, ce qui est une des caractéristiques définissant ces trois relations.

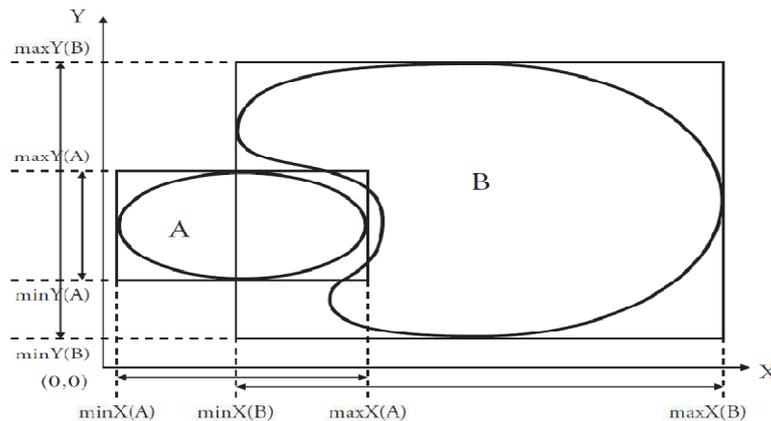


Figure 9. Confusion d'une disjonction avec un chevauchement

### b) Méthode de Walker

Quelques méthodes ont été proposées pour effectuer des détections de relations spatiales, et surtout pour les représenter de manière efficace. On peut citer en particulier la représentation à l'aide de matrices de pondération mise au point par Walker et al. [29]. Cette méthode a été conçue principalement pour les systèmes de gestion de bases de données géographiques et s'appuie sur un calcul de distance entre les objets dans l'image étudiée. Les résultats des différents calculs de distances effectués au sein de l'image sont stockés dans une matrice carrée symétrique de taille égale au nombre d'objets présents dans l'image. L'élément  $M[i, j]$  est égal à la distance séparant l'objet  $i$  de l'objet  $j$ . La matrice ainsi construite est appelée matrice de contiguïté et permet de déduire les relations spatiales. Par exemple, pour le groupe d'objets présenté par la figure 10 :

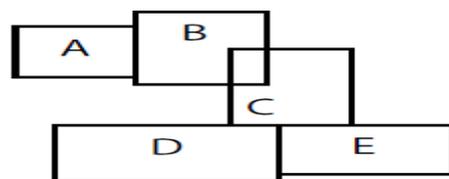


Figure 10. Exemple d'utilisation de la méthode de Walker et al.

On obtient la matrice suivante :

$$M = \begin{vmatrix} 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 2 & 0 & 0 \\ 0 & 2 & 0 & 1 & 1 \\ 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 1 & 0 \end{vmatrix}$$

Les valeurs composant la matrice sont les degrés de relation présents entre les différents couples d'objets. La force de chacun de ces degrés permet de déterminer la relation. Dans la littérature, les auteurs définissent les correspondances illustrées dans le tableau 4.

Relation	Poids
Point commun	7
Contient	6
Chevauche	5
Adjacent	4
Chevauchement par le plus rectangle englobant l'autre	3
Chevauchement des rectangles conteneurs	2
Séparé	1
Egal	0

Tableau 4. Les correspondances entre poids et relation

Cette méthode diffère de celle que nous proposons à plusieurs points de vue : pour commencer, elle ne traite pas tout à fait des huit relations primaires, et nécessite la prise en compte de relations particulières mettant en jeu les plus petits rectangles conteneurs. Ensuite, le chevauchement pose le même problème que la méthode de Kim et Um : il nécessite de connaître non seulement les parties « visibles » des objets, mais aussi leurs parties « cachées », et ceci n'est pas applicable dans notre cas.

### c) *Méthode de Lee*

Plus qu'une méthode de détection des relations spatiales à été proposée, Lee et al. [30] ont mis au point une méthode de représentation des relations spatiales. Ils fragmentent tout d'abord l'image en zones homogènes, de la même manière que nous le faisons dans notre méthode, puis établissent un graphe d'« adjacence ». Ce graphe permet de relier les régions adjacentes deux à deux, et de décrire ainsi l'image sous forme de relations d'objets. Ils donnent l'exemple repris dans la figure 11 pour illustrer la méthode :

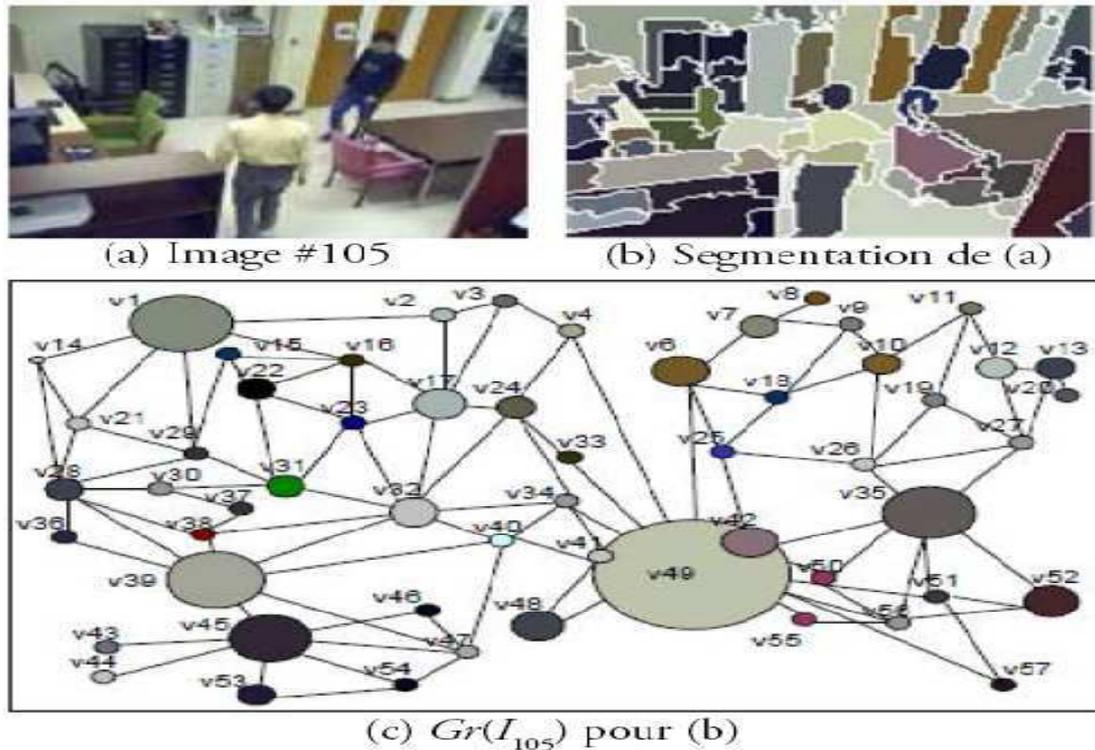


Figure 11. Application de la méthode de Lee.

La figure 11 montre une image, sa décomposition en objets et le graphe d'adjacence correspondant. Cette méthode permet de décrire une image efficacement.

### 3.2.3.2. Les relations temporelles

Les relations temporelles sont des relations de cohérence explicite ou présumées qui sont utilisées pour décrire des événements ou des états ordonnés par rapport au temps. La représentation du temps a toujours été un enjeu crucial tant en intelligence artificielle que dans la gestion de bases de données ou dans les systèmes d'informations géographiques. L'ajout de la dimension temps, dans un système, permet de gérer des notions qui sont plus proches de l'utilisateur : cela permet d'analyser les évolutions, les mouvements, les changements d'états des phénomènes observés, ou des événements. Pour parler du temps, il est nécessaire de distinguer plusieurs notions. Premièrement, les «temps» absolus sont des instants ponctuels ou des intervalles de temps ayant une durée. Ceux-ci permettent de dater ce que l'on appelle des «états» qui sont des situations stables du monde par rapport à une propriété. Les «temps» permettent également de dater des «événements» qui provoquent un changement de la situation du monde. Il est intéressant aussi de faire la distinction entre deux types d'événements dans le traitement du temps. D'une part les événements instantanés qui peuvent être facilement gérés par une ligne temporelle, et d'autre part les événements ayant une certaine durée. Les relations temporelles permettent de décrire des événements au cours du temps, en effet, les

principales représentations qualitatives du temps sont l'algèbre d'intervalles d'Allen [31] [32] et l'algèbre de points de Vilain et Kautz [33].

**a) Algèbre de points de Vilain et Kautz**

Dans l'algèbre de points de Vilain et Kautz, trois relations de base, « précède ( $\prec$ ) », « identique ( $=$ ) » et « suit ( $\succ$ ) », sont considérées.

**b) Algèbre d'intervalles d'Allen**

Dans la théorie d'Allen, 13 relations de base (ou relations atomiques) décrivent toutes les manières possibles d'ordonner les extrémités de deux intervalles (voir figure 11). Allen propose un formalisme basé sur une logique temporelle utilisée pour raisonner sur des événements, des actions, des convictions, des intentions, des causalités et également utilisée pour servir de cadre à la résolution de problèmes. La primitive temporelle du modèle d'Allen est l'intervalle, cela lui permet de raisonner sur des processus ayant une certaine durée. Sur base de deux intervalles, il définit alors 13 relations binaires mutuellement exclusives. Dans ce cas, le temps est considéré comme continu et non borné.

Posons  $T$  comme un ensemble d'instants mesurés, cet ensemble est isomorphe à un ensemble de réels. En d'autres termes, considérons un ensemble d'instants  $T$  qui partagent les mêmes propriétés que l'ensemble des nombres réels. La mesure du temps est donc assimilée à la mesure de nombres réels. Posons également  $I$  comme étant l'ensemble des intervalles de temps. Soit  $i$  un intervalle de temps de  $I$ , on a alors :  $i = [t_1, t_2]$ , où  $t_1, t_2$  appartiennent à  $T$ . De plus, on a également que :  $t_1 < t_2$ . Deux opérateurs sont également définis, il s'agit de *Begin*( $i$ ) et de *End* ( $i$ ) qui représentent respectivement l'instant de départ et l'instant de fin de l'intervalle  $i$ . En considérant également les opérateurs de comparaison logique, nous pouvons représenter formellement les 13 relations possibles dans la figure 12 :

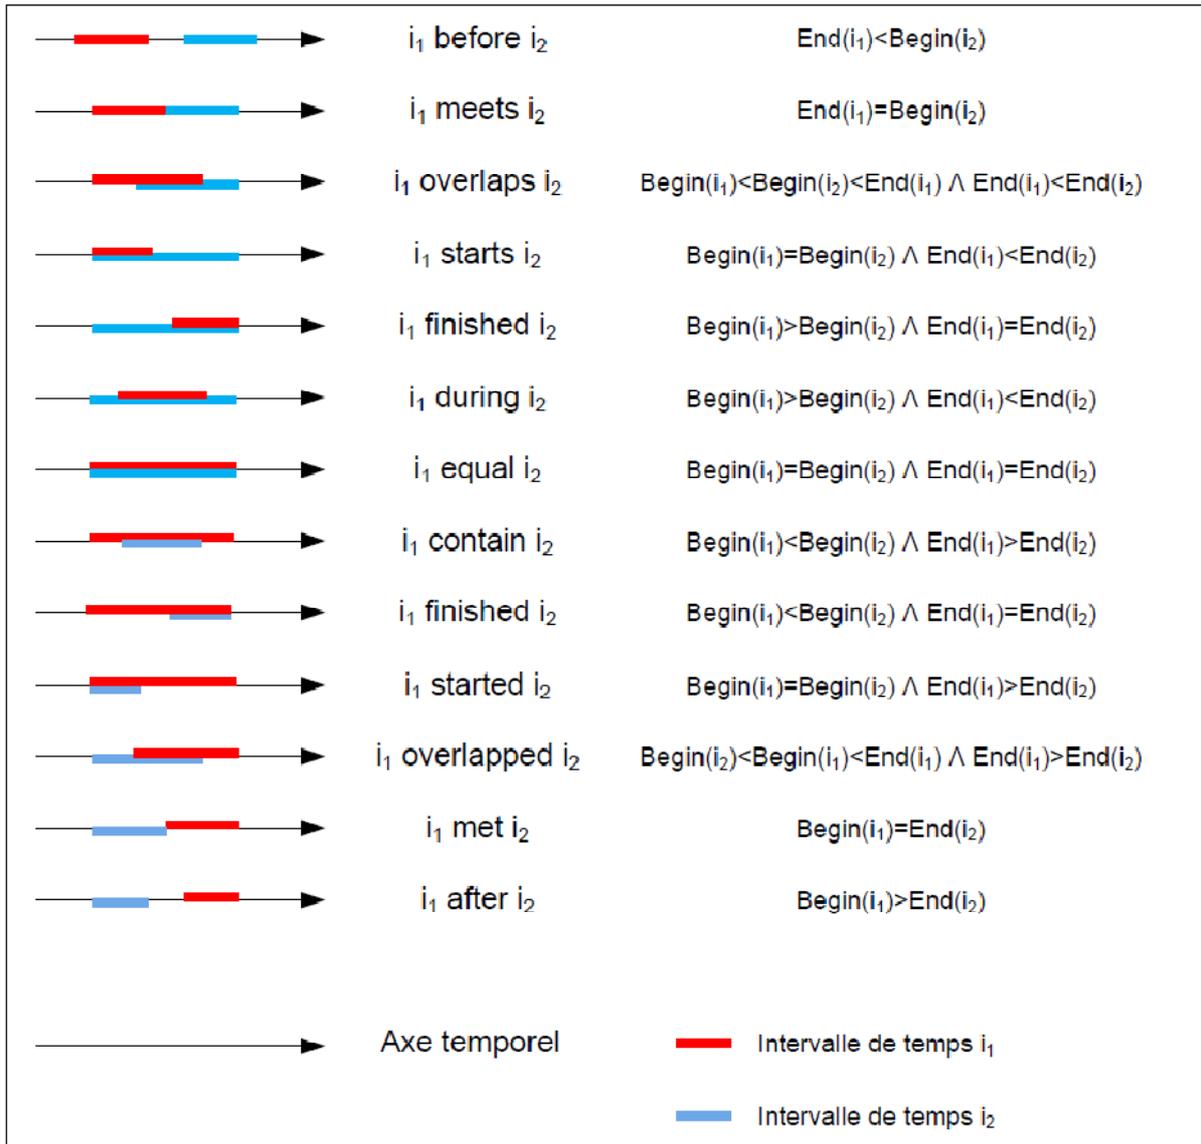


Figure 12. Relations sur les intervalles temporels d'Allen [30].

Les relations de base peuvent être combinées par disjonction, on obtient alors  $2^{13}$  relations. Il n'y a pas de représentation de la durée des intervalles.

### 3.2.3.3. Les relations spatio-temporelles

Les relations spatio-temporelles peuvent être considérées comme l'étape logique suivante aux relations spatiales et aux relations temporelles [34]. La plupart de formalismes de modélisations spatio-temporelles sont basés sur une combinaison des modèles de relations spatiales et modèles de relations temporelles [35][36]. Plusieurs travaux sont réalisés dans la détection des relations spatio-temporelles, notamment Ren et al. [37], Bittner et al. [38], Claramunt et al. [39], Inkej et al. [40] et Salamt et al. [41], ses travaux s'appuient sur l'utilisation des relations topologiques et directionnelles comme des relations spatiales et les algèbres d'intervalles d'Allen comme des

relations temporelles. Donc les relations spatio-temporelles présentent la combinaison entre les relations spatiales et les algèbres d'intervalles temporelles d'Allen.

**a) Formalisme de Ren** [37]

C'est un formalisme qui utilise l'algèbre d'intervalle d'Allen et les relations topologiques et directionnelles. Ils sont choisis comme domaine d'application, la récupération des informations vidéo. Ce formalisme montre comment l'utilisation des connaissances sémantiques spatio-temporelles change selon la façon dont la recherche moderne est conduite.

**b) Formalisme de Bittner** [38]

Comme le formalisme de Ren, ils ont choisi d'utiliser l'algèbre d'intervalle d'Allen et les relations topologiques et directionnelles mais dans la modélisation des relations entre des objets en analyse d'images. Ils décrivent l'emplacement relatif des objets spatio-temporels dans les surfaces ou tout au long des chemins. Ils explorent les relations entre le contexte, les inférences et les relations spatio-temporelles qui existent au sein de ces inférences.

**c) Formalisme de Claramunt** [39]

Utilisé dans la modélisation de l'évolution des régions en analyse d'images et exploitant toujours l'algèbre d'intervalle d'Allen et les relations topologiques et directionnelles. Ce formalisme introduit une nouvelle approche qui combine les relations topologiques entre les régions dans un espace à deux dimensions avec des relations temporelles entre les intervalles de temps convexes. Les relations résultantes sont définies et présentées dans un espace à trois dimensions.

**d) Formalisme de Salamat** [40]

C'est un formalisme qui se base sur une analyse spatio-temporelle floue des images numériques pour la détection des mouvements, en utilisant toujours l'algèbre d'intervalle d'Allen.

**e) Formalisme d'Inkej** [41]

Ils ont choisi comme domaine d'application le traitement des images médicales en utilisant l'algèbre d'intervalle d'Allen et les relations topologiques et directionnelles. Ils introduisent les relations spatio-temporelles floues du type même endroit/instant différent et endroit différent/instant différent. Ces relations sont définies par les relations d'Allen floues et les mesures de similarité floues.

La plupart des travaux réalisés en détections de relations spatio-temporelles sont basés sur les relations spatiales (topologiques) et sur les algèbres d'intervalles. En fait, l'utilisation de l'algèbre d'intervalle d'Allen permet de représenter toutes les manières possibles des relations temporelles, ainsi les relations topologiques sont très importantes dont leurs utilisations puisqu'elles permettent de représenter de façon linguistique la configuration spatiale. Mais, en parlant de détection des changements, nous dressant dans la suite, les différentes techniques de détection rencontrées dans la littérature.

## 4. Les techniques de détection des changements

L'inventaire des techniques d'occupation et d'utilisation des sols et de leur répartition constitue un enjeu fort pour l'analyse des écosystèmes. Les changements majeurs intervenus au cours des trois derniers siècles ont été localisés et identifiés à l'échelle mondiale [42]. En revanche, les changements progressifs, de faible amplitude, et/ou touchant des superficies peu importantes voire négligeables à l'échelle mondiale, sont encore largement méconnus. Or, s'ils contribuent peu aux modifications des échanges énergiques globaux, ces changements peuvent entraîner des conséquences environnementales ayant un impact majeur à une échelle locale, voire régionale. Les inventaires d'occupation et d'utilisation des sols sont, dans la quasi-totalité des cas réalisés par télédétection. De nombreux travaux de recherches concernant la détection des changements actuels des surfaces terrestres à partir de données de télédétection ont été effectués depuis une vingtaine d'années [43] [44]. Cependant, selon les indices de changement retenus et les méthodes de détection appliquées, les résultats obtenus montrent des différences qui peuvent être significatives tant au niveau quantitatif sur l'importance des modifications intervenues sur une période donnée [45], qu'au niveau qualitatif sur les types de changements observés [46]. Par ailleurs, pour une méthode donnée, si l'on change d'application et de données, la qualité des résultats obtenus varie également, parfois de façon significative. De plus, l'introduction d'autres sources d'information que la télédétection dans le processus de détection du changement a également un impact sur la qualité des résultats. En conséquence, il n'existe pas à l'heure actuelle de méthode de détection du changement qui soit réellement générique, ou au moins facilement transposable d'une application à une autre. Coppin *et al.* [44] ont identifié dix grands types de méthodes de détection qui reposent sur des techniques variées de traitement d'images, incluant la soustraction d'images, le croisement de classifications, les analyses en composantes principales (ACP : Analyse Statistique Multivariée), le calcul de vecteurs de changement, ou encore l'utilisation de réseaux neuronaux. Le type de méthode utilisée dépend largement de la zone d'étude, du type de changement à détecter, et de la résolution spatiale et temporelle des données.

### 4.1. Méthode par transformation [47]

La catégorie de transformation inclut l'analyse en composante principale, Gram-Schmidt (GS), et transformations Chi-2. Un avantage de ces méthodes est la réduction des données redondantes entre bandes et l'accentuation de l'information différente dans les composants dérivés. Cependant, ils ne peuvent pas fournir des matrices de changement détaillées et exigent la sélection de seuils pour identifier les régions changées [48]. Un autre inconvénient est la difficulté dans l'interprétation et le labelling de l'information du changement sur les images transformées. Ces

méthodes sont plus complexes que les méthodes algébriques ; mais encore assez simples. Elles offrent la possibilité d'utiliser plusieurs bandes à la fois pour la détection de changements. Mais, il est difficile d'identifier les changements détectés car l'analyste doit posséder une bonne connaissance pour le choix des composantes et des seuils. Donc, on peut conclure que ces méthodes sont assez simples et fournissent de l'information sur les trois objets essentiels du milieu côtier, soit la végétation, le sol et l'eau.

#### **4.2. Méthode algébrique**

La méthode algébrique inclut plusieurs algorithmes tel que : différence d'images, régression d'image, ratio d'images, différence de l'index de la végétation, analyse du vecteur du changement (CVA) et soustraction de l'origine [44]. Ces algorithmes ont une caractéristique commune, celle de sélectionner des seuils pour déterminer les régions changées. Ces méthodes sont relativement simples, faciles à implémenter et à interpréter. Dans cette catégorie, deux aspects sont critiques pour les résultats de la détection du changement, la sélection de la bande d'image et les indices de bâti convenables et la sélection des seuils convenables pour identifier les régions changées. Lyon et al. [49] ont comparé sept indices de végétation dans trois dates différentes de données pour la détection du changement sur terre et ont conclu que la technique de différence de NDVI (Indice de Végétation différentiel normalisé) a démontré les meilleures résultats de détection du changement de la végétation.

#### **4.3. Méthode par classification**

La catégorie de la classification inclut la comparaison post classification, l'analyse spectrale-temporelle combinée, l'algorithme expectation-maximisation (EM), la détection du changement non supervisée et la détection du changement hybride [50]. Ces méthodes sont basées sur des images classifiées dans lesquelles la qualité et la quantité des données de l'échantillon sont cruciales pour produire des résultats de classification de bonne qualité. L'avantage majeur de ces méthodes est la capacité de fournir une matrice d'information du changement et de réduire les impacts externes des différences atmosphériques et environnementaux entre les images multi-temporelles. Cependant, sélectionner des échantillons de qualité et suffisamment nombreux pour la classification de l'image est souvent difficile. Le temps consommé et la difficulté de produire des classifications exactes engendrent souvent des résultats de détection de changement peu satisfaisante, surtout quand les données et les échantillons de qualité ne sont pas disponibles.

#### **4.4. Méthode par analyse visuelle [51]**

La catégorie de l'analyse visuelle inclut l'interprétation visuelle d'image multi-temporelle composée et les cartes de régions changées. Cette méthode peut faire plein usage de l'expérience et les

connaissances d'un analyste. La texture, la forme, la dimension et les modèles des images sont des éléments clés utiles pour l'identification des changements à travers l'interprétation visuelle. Ces éléments ne sont pas souvent utilisés dans l'analyse de la détection du changement numérique à cause de la difficulté dans l'extraction de ces éléments. L'inconvénient de cette méthode est le grand temps consommé pour une application de détection du changement pour de grandes régions et c'est aussi difficile de faire une mise à jour adéquate des résultats de la détection du changement.

L'utilisation de la méthode de comparaison post classification convient à notre méthodologie, puisque les données des différentes dates ont été classées séparément. Cette méthode permet de minimiser les effets atmosphériques et d'utiliser des capteurs différents lors de l'acquisition des images multi-dates, en fait, c'est la méthode la plus évidente qui compare, indépendamment deux images classées.

#### **4.5. Modèles avancés**

La catégorie de la détection du changement basée sur le modèle avancée inclut le modèle de réflectance de Li-Strahler, le modèle spectral, et le modèle de l'estimation des paramètres biophysiques. Dans ces méthodes, les valeurs de la réflectance de l'image sont souvent converties en paramètres physiques ou des fractions à travers des modèles linéaires ou non linéaire [50]. Les paramètres transformés sont plus intuitifs à interpréter et meilleures pour extraire de l'information de végétation que des signatures spectrales. L'inconvénient de ces méthodes est qu'il est difficile de développer des processus qui génèrent des modèles convenables pour la conversion des réflectances de l'image en paramètres biophysiques.

En plus des cinq catégories de techniques de la détection du changement discutées au-dessus, il y a aussi quelques méthodes qui ne peuvent pas être attribuées à une des catégories indiquées au-dessus. Par exemple, Wang [52] a utilisé un système de vision basé sur les connaissances pour détecter le changement de terre à bordures urbaines. Lambin et Strahler [53] ont utilisé trois indicateurs, indices de la végétation, température de la surface de la terre et structure spatiale, pour détecter le changement de la terre en Afrique ouest. Lawrence et Ripple [54] ont utilisé les courbes de changements et Hussin et al. [55] ont utilisé un modèle de production de région pour détecter les changements de la forêt. Aussi, la catégorie de la détection du changement basée sur les SIG à la capacité d'incorporer les données de sources différentes dans l'application de la détection du changement. Cependant, associer des données de sources différentes avec des exactitudes de données et des formats différentes souvent affectent les résultats de la détection du changement. La plupart des applications antérieures d'approches SIG dans la détection du changement ont été concentrées sur les régions urbaines. C'est probablement parce que les méthodes de la détection du changement traditionnelles ont souvent des résultats pauvres dû à la complexité des paysages urbains; ne peuvent pas utiliser l'analyse des données multi-source efficacement. Après la détection des

changements, nous pouvons passer à étudier les principales techniques de prévision des changements.

## 5. Les techniques de prévision des changements

Les articles d'état de l'art de Singh [43], Lu [50] et Coppin [44] proposent une revue plus complète des approches existantes de détection de changements en télédétection. Notons que les catégories utilisées pour classifier les méthodes de détection diffèrent d'un article à l'autre. En particulier, Coppin *et al.* [44] proposent une taxonomie distinguant le cas bi-dates, c.à.d. la détection de changements réalisée uniquement entre deux images acquises à deux instants différents, du cas multi-dates, couramment appelé « trajectoire temporelle », dont l'objectif est de réaliser le suivi d'une scène à partir d'une série d'observations sur une longue durée (évolution des cultures, du tissu urbain, etc.). Cependant, les méthodes d'analyse de la trajectoire temporelle sont très peu nombreuses et correspondent généralement à des adaptations de méthodes bi-dates au cas multi-dates. En général, les méthodes bi temporelles sont plutôt employées pour l'analyse des changements rapides, à une échelle locale, et exploitent des données à haute résolution spatiale. A l'inverse, les méthodes multi temporelles, plutôt centrées sur l'analyse des évolutions lentes ou des phénomènes à grande échelle, reposent sur l'analyse des profils d'évolution à haute fréquence temporelle dérivés de séries grand champ acquises par des capteurs à basse résolution spatiale et haute répétitivité temporelle. La plupart de ces systèmes ont traité la composante de détection de changements dont l'objectif est de générer une image représentant les zones de changements/ non changement entre deux images  $I_1$  et  $I_2$  (ou séquences d'images) acquises à deux instants différents (ou intervalles de temps), image couramment appelée carte de changements. Le problème de détection de changement est donc réduit à l'élaboration d'un critère ou d'une mesure permettant de faciliter la discrimination des changements et à l'identification des changements de manière à obtenir une partition de la scène observée en zone de changements et de non-changement. Peu d'entre eux ont résolu le problème de l'explication et de la prédiction des événements spatio-temporels à partir des séries temporelles d'images satellite ou bien des systèmes qui permettent de quantifier les incertitudes et de fournir une aide à la décision crédible. Cependant, force est de constater que ces techniques ne satisfont pas complètement les géographes qui exploitent pourtant, de plus en plus couramment, les données extraites des images dans leurs études afin de prédire le futur, c'est à dire de prévoir les conséquences des différentes alternatives dans un mois ou plusieurs afin de mieux évaluer celle-ci et de faire un choix. On distingue trois familles de méthodes de prédiction des changements, les méthodes mathématiques, les méthodes intelligentes et celles probabilistes.

### **5.1. Les méthodes mathématiques**

Les méthodes mathématiques, dites aussi raisonnement dur, sont basées sur la résolution d'un ensemble d'équations pour atteindre un équilibre. Ces méthodes se basent sur la simulation des prises de décision par la programmation linéaire [56]. Ces modèles utilisent aussi les systèmes d'information géographiques, d'une part pour collecter les données et d'autre part [57], déterminer les caractéristiques spatiales et les critères nécessaires pour la programmation linéaire [58].

### **5.2. Les modèles intelligents**

Ce sont les modèles d'évolution qui se basent sur l'intelligence artificielle comme les méthodes neuronales telles que les cartes de Kohonen [59], les modèles cellulaires qui se basent principalement sur les automates cellulaires [60] et les modèles multi-agents qui se basent sur la décomposition d'un problème en plusieurs tâches traitées en même temps [61].

### **5.3. Les modèles probabilistes**

Les modèles de prédiction sont généralement des modèles stochastiques faisant appel au calcul de probabilités, ils permettent de décrire et de prédire les caractéristiques d'un système donné sous différentes configurations. Dès que ces caractéristiques sont connues, la meilleure solution parmi les alternatives évaluées est choisie. Les connaissances manipulées par les systèmes intelligents en interprétation d'images sont généralement incertaines et imprécises. La prise en compte de ces critères constitue une évolution importante de ces nouveaux systèmes. L'incertitude est relative à la vérité d'une information qui caractérise sa conformité par rapport à la réalité. Elle exprime un doute sur la validité de l'information. L'imprécision concerne le contenu de l'information et porte sur un défaut quantitatif de connaissance. Elle peut représenter la difficulté rencontrée par les experts à exprimer clairement une information. Une information peut être à la fois incertaine et imprécise. Dans le contexte des données géographiques, ces caractéristiques sont présentes dans les images (incertitude) ou dans les données recueillies auprès des experts (incertitude, imprécision). Les causes d'incertitude proviennent généralement des défauts sur les capteurs, des mauvaises conditions de prise de vue, des données redondantes ou conflictuelles issues de différents capteurs et des opinions contraires données par les experts.

Un processus stochastique  $X = \{X_t : t \in T\}$  est une suite de variables aléatoires indexées et prenant leurs valeurs dans un unique espace des observations  $X$ . Le processus  $X$  est lui-même une variable aléatoire. Il est courant de considérer un processus à temps discret où l'ensemble  $T$  est à valeurs discrètes. Le cas continu correspond à une indexation continue du processus. Un processus stochastique est complètement déterminé par la connaissance de la distribution de probabilité conjointe sur un espace discret  $T$ . Dans la plupart des cas l'espace discret correspond à une indexation des variables aléatoires sur l'ensemble d'entiers  $N$ . Prenons un espace d'indexation  $T$

discret et fini. Celui-ci peut être mis en bijection avec l'intervalle  $[0, n]$  où  $n$  est le cardinal de l'ensemble. Alors le processus se réécrit par  $X = \{X_i; 1 \leq i \leq n\}$ . Nous nous référons à ce type de processus par la notation  $X_n$  pour mettre en avant le cardinal de l'index. Les processus stochastiques peuvent être classés en sous-classes en particulierisant leur distribution de probabilité. Les probabilités permettent depuis longtemps de représenter l'incertitude. Dans le domaine de l'IA plusieurs théories, utilisées en traitement d'images, ont fait leur apparition. Plusieurs modèles se sont plus particulièrement intéressés à la prise en compte de la dimension temporelle et des données incertaines. Dans la section suivante nous allons présenter les formalismes généralement utilisés pour modéliser des informations incertaines et temporelles: les Automates Temporisés, les modèles experts, les Réseaux Bayésiens et les Modèles de Markov Cachés.

### **5.3.1. Les automates Temporisés**

Largouet [62] a démontré que les automates temporisés permettent au mieux de représenter les contraintes temporelles et les transitions d'états par rapport aux différents formalismes utilisés pour la supervision des systèmes dynamiques. Dans le cadre du projet Bretagne Eau Pure, ses travaux définissent une méthode pour interpréter une séquence d'images de télédétection portant sur un paysage agricole pour lesquelles il faut définir l'occupation du sol. La parcelle agricole est donc considérée comme un système dynamique qui change d'état à la faveur des rotations annuelles et des pratiques culturales. La contribution principale de cette thèse est une nouvelle méthode de reconnaissance de l'occupation du sol dont l'originalité est de s'appuyer sur un modèle d'évolution de la parcelle agricole pour améliorer les résultats obtenus par les outils traditionnels de classification d'images à l'aide d'automates temporisés. Le système développé par Largouet, n'a pris en compte que l'évolution temporelle et non pas l'évolution spatiale de la parcelle. De plus, le problème a été limité à l'amélioration de la classification en tirant profit de l'ensemble des images de la série et des connaissances sur le domaine pour lever les ambiguïtés entre les cultures et non pas la modélisation spatio-temporelle. Toutefois, cet organisme n'a pour le moment pas été appliqué à une séquence d'images d'un autre domaine et il ne peut être retenu dans le cadre de notre projet.

### **5.3.2. Les modèles experts**

Les modèles experts utilisent les techniques de mesure confiance - comme les facteurs de certitude et la théorie des évidences – et les connaissances provenant de l'expert du domaine [63]. Le majeur inconvénient de ces modèles est qu'ils doivent prendre en considération tous les aspects du problème considéré, ce qui limite leur application à des régions très réduites.

### 5.3.3. Les réseaux Bayésiens

D'autres approches se sont plus particulièrement intéressées à la prise en compte des données incertaines. L'attrait des réseaux Bayésiens réside dans leur capacité à représenter à la fois les données qualitatives et quantitatives du problème. La topologie du graphe représente la nature qualitative de la relation de causalité entre les possibles événements qui sont décrits, de manière quantitative par des valeurs numériques, dans les nœuds du graphe. Les réseaux Bayésiens sont essentiellement utilisés pour calculer les probabilités conditionnelles des variables reliées les unes aux autres par des relations de cause à effet. Cette utilisation s'appelle l'inférence. Un type d'inférence particulière est la mise à jour des probabilités qui survient suite à un ensemble d'observations. L'inférence revient à un problème de calcul puisque la définition de probabilité étant entièrement donnée, on peut, en principe, tout calculer. Ces modèles ont été employés dans plusieurs domaines ; diagnostic (médical et industriel), analyse de risques, détection de spams, datamining, détection de fraudes, exploitation du retour d'expérience, modélisation et simulation de systèmes complexes, détection d'intrusions, TextMining, analyse de BioPuces analyse de trajectoires de santé, pour la reconnaissance de comportement dans le domaine de la surveillance...

En analyse des images satellitaires, plusieurs systèmes ont été développés ; Marengoni [64] a construit un système original (appelé ASCENDER I) pour la détection et la reconstruction de bâtiment à partir des images multiples, il a détecté presque 90 pour cent des bâtiments, L'utilisation des réseaux Bayésiens hiérarchique combinée avec la théorie de l'utilité permet d'augmenter le taux de reconnaissance (ASCENDER II). Kumar [65] a conçu une approche probabiliste pour l'interprétation d'image, elle se base sur la modélisation d'un réseau Bayésien de 2 niveaux, ils utilisent des réseaux Bayésiens définis sur des graphes de régions pour extraire l'information d'images satellitaires. Singhalt [66] a conçu une nouvelle technique de détection les régions intéressantes d'une image et de fusion des données issues de plusieurs capteurs. Ce système utilise les réseaux Bayésiens hiérarchiques. Heas et Datcu [67] décrivent une méthode plus complexe pour l'extraction d'information dans les STIS à haute résolution où les informations spatiale et temporelle sont utilisées conjointement. Ils proposent une méthode Bayésienne où plusieurs niveaux d'information sont extraits. En particulier ils se placent dans le concept de la fouille d'information et proposent une modélisation hiérarchique qui va des données vers l'utilisateur. Nous présentons uniquement l'extraction d'information non supervisée qui constitue la première brique du système. Cette extraction est l'inférence de graphes qui modélisent des trajectoires de clusters dynamiques qui codent les structures spatio-temporelles. Cette modélisation exploite la constatation que l'analyse doit être temporellement et spatialement localisée. Ainsi, les structures spatio-temporelles sont décrites par des modèles paramétriques et des mélanges de lois. Ensuite, pour prendre en compte l'évolution dans les STIS, les structures sont reliées temporellement à l'aide de graphes. Ce même genre d'idée a été repris dans le travail de Gueguen [68]. Dans cet article, deux approches sont

comparées. La première approche essaie de regrouper des trajectoires de régions, où la similarité est fondée sur l'information de texture. L'autre approche modélise l'évolution de régions spatiales prédéfinies en se basant sur une segmentation commune à toutes les images [69]. Néanmoins on ne peut pas se servir de ces travaux car ils ont traité la composante de l'analyse d'images (segmentation, classification, fusion...) c'est à dire la reconnaissance des éléments contenus dans l'image et ils n'ont pas mis l'accent sur l'interprétation des événements spatio-temporels à partir d'une séquence d'images. Tous ces systèmes ont utilisé les approches bayésiennes statiques sans tenir compte de l'aspect temporel et dynamique des images satellitaires. Les Réseaux Bayésiens Dynamiques (RBD) sont une extension des Réseaux Bayésiens classiques qui permet de représenter l'évolution temporelle des variables. Il est composé de sous-graphes séparés temporellement et interconnectés par des liens reconfigurables, c'est-à-dire que les nœuds du réseau peuvent être non seulement connectés aux autres nœuds de la même tranche de temps mais aussi à des nœuds de la tranche suivante ou précédente. Un grand nombre d'applications ont utilisé ce type de modèles, par exemple en reconnaissance de la parole [70], en reconnaissance d'écriture manuscrite [71] et en vidéosurveillance [72]. Par contre en interprétation des images satellitaires il s'agit d'un domaine de recherche récent et l'offre bibliographique et logicielle est encore pauvre et incomplète.

#### **5.3.4. Les Modèles de Markov Cachés (MMC)**

Les chaînes de Markov sont un outil mathématique issu des probabilités et dont les domaines d'applications sont assez vastes : intelligence artificielle, génétique, météorologie, ...

Les modèles de Markov cachés (MMC) ont été introduits dans les années 1960-70. D'abord utilisés en reconnaissance de la parole à partir des années 80 [73], ils ont ensuite été appliqués à la reconnaissance de textes manuscrits [71], à la bioinformatique, la modélisation de signaux acoustiques, les circuits micro-électroniques... Ces travaux nous amènent à analyser les techniques de reconnaissance fondées sur les MMC afin d'évaluer leur application à la résolution de notre problème. En effet, la reconnaissance d'une suite d'états d'un objet d'images peut être comparée à la reconnaissance d'une suite de lettres et les avantages énoncés sur cette technique sont attirants (formalisation, algorithmes efficaces, résultats). Les MMC sont généralement utilisés pour résoudre trois types de problèmes :

- le calcul de la probabilité d'une séquence donnée ;
- le calcul du chemin le plus probable, c'est-à-dire la suite d'états optimale, connaissant une suite d'observations ;
- la mise au point des paramètres du modèle.

Il faut distinguer le MMC discret du cas continu. Bien qu'il soit possible de quantifier les observations continues à l'aide d'un dictionnaire de codage, il y a une série de dégradation d'informations associée à ce type de quantification. L'autre solution, qui est peut-être encore un peu

plus théorique, serait celle d'inclure les densités d'observations continues dans ce modèle à l'aide d'un MMC continu [73]. Mais, l'entraînement d'un modèle de Markov à temps continu nécessite la disponibilité d'une très grande quantité de données. Ainsi que l'implémentation de ce modèle markovien est plus difficile et plus lente par rapport à un MMC discret (voir tableau 5) [74].

	A. MMC Continu	B. MMC Discret
<b>Nombre de paramètres à estimer</b>	Un nombre élevé de paramètres	Moins de paramètres que A.
<b>Hypothèses sur la nature de transformations</b>	Importants	Moins importants que A.
<b>Implémentation</b>	Difficile et lent	Plus facile et plus rapide que A.
<b>Nombre de corpus d'apprentissage</b>	Plus élevés que B.	Moyen

Tableau 5. Étude comparative entre le MMC Discret et le MMC Continu

### 5.3.5. Typologie des MMC

Différentes topologies de MMC [73] peuvent être envisagées, à commencer par le modèle ergodique, celui où chaque état peut être atteint à partir de n'importe quel autre en un nombre fini de transitions (figure 13). Le modèle est donc caractérisé par une matrice  $T$  aux coefficients strictement positifs.

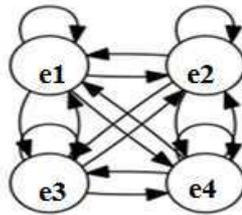


Figure 13. Modèle de chaîne de Markov ergodique

Une structure couramment utilisée est celle des modèles de Bakis, dits également modèles gauche-droite (figure 14), ainsi appelés parce qu'ils n'autorisent aucune transition d'un état vers un autre d'indice inférieur : les états qui se succèdent ont donc des indices égaux ou supérieurs aux précédents. Une fois dans le dernier état, le système est condamné à y rester : c'est pourquoi la probabilité initiale du premier état est posée égale à 1, les autres étant égales à 0.

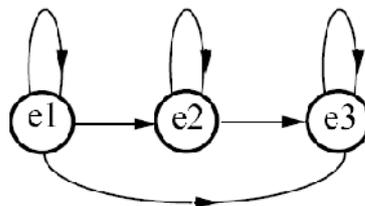


Figure 14. Modèle de Bakis à 3 états

Dans le même ordre d'idées, les sauts de nombreux états consécutifs sont souvent interdits ( $T(i, j) = 0, j - i > \Delta$ ). Une variante du modèle gauche-droite est le modèle gauche-droite parallèle, utile, par exemple, en reconnaissance de la parole, où il permet de prendre en compte la possibilité de multiples prononciations d'un même mot. Les procédures de ré-estimation des paramètres d'un modèle de Markov sont telles que, si certains de ces paramètres sont initialement mis à zéro, ils resteront nuls tout au long de la phase d'entraînement. Ceci permet donc, de conserver les contraintes imposées à la structure du modèle. Dans le cas spécifique d'un modèle de Bakis, l'entraînement ne peut toutefois pas être réalisé à partir d'une seule séquence d'observations car, étant donné la nature du modèle, trop peu d'observations dans une séquence sont associées à un état particulier. Afin de disposer de données suffisantes pour l'estimation des paramètres, la procédure de ré-estimation doit donc être modifiée de façon à prendre en compte des séquences d'observations multiples. Bien sur, il existe évidemment encore bien d'autres topologies de MMC. On peut montrer que la probabilité qu'un état  $S_i$  produise  $d$  observations élémentaires est une fonction exponentielle décroissante de  $d$  [73]. Ceci constitue l'une des plus grandes faiblesses des modèles de Markov car cette modélisation s'avère inappropriée pour représenter la plupart des signaux physiques. Une amélioration possible du modèle est d'inclure explicitement les distributions  $P_i(d)$  de la durée des états, au prix cependant d'une augmentation du nombre de paramètres et, surtout, du volume de calcul. Une autre solution, beaucoup plus avantageuse, consiste à introduire une condition de durée minimale des états du MMC. Ceci s'avère particulièrement utile lorsque les séquences comportent davantage de boucles que de transitions d'un état vers un autre, les exponentielles prenant alors des valeurs beaucoup trop faibles.

Du modèle de Markov caché dérivent d'autres modèles comme le modèle de Markov hiérarchique, le modèle de Markov gaussien ou encore appelé filtre, le modèle de Markov couplé, le modèle de Markov triplet et les modèles de Markov à temps continu.

### 5.3.5.1. MMC hiérarchique

Le modèle de Markov hiérarchique est une extension des MMC désigné pour modéliser un domaine avec une structure hiérarchique qui représente les dépendances conditionnelles entre les différents niveaux. Dans un Modèle de Markov hiérarchique, les états peuvent émettre une ou plusieurs observations. Si l'état émet une seule observation alors on l'appelle état de production, s'il s'agit de plusieurs observations on l'appelle état absolu. La figure 15 représente un modèle de Markov hiérarchique dans lequel, on peut voir la représentation hiérarchique des différents états et la représentation des dépendances par les flèches orientées entre les différents niveaux [75].

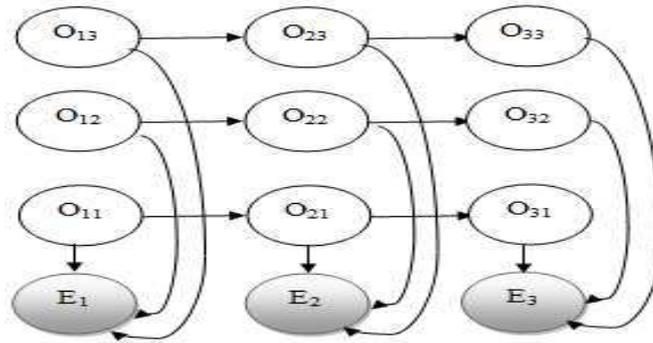


Figure 15. Exemple de structure de modèle de Markov hiérarchique

### 5.3.5.2. MMC gaussien

Les filtres Bayésiens sont plus adaptés à l'expérimentation car en pratique, la valeur que nous observons pour une grandeur est souvent biaisée, ne serait-ce que par la précision du capteur. Un filtre Bayésien peut être représenté par un réseau Bayésien dynamique qui ne possède qu'une variable d'état et qu'une variable observation. Lorsque, pour un modèle de Markov, l'a priori initial est gaussien, les variables d'états et d'observations sont continues et les modèles de transition et d'observation sont gaussiens, ce modèle est appelé un filtre de Kalman (ou encore systèmes dynamiques linéaires).

### 5.3.5.3. MMC à temps continu

Jusqu'à présent, seuls des Modèles de Markov Cachés modélisant des séquences d'observations discrètes ont été envisagés : ces observations prenaient des valeurs appartenant à un alphabet fini, et leurs probabilités étaient définies dans chaque état par un ensemble fini de valeurs. Le problème est que les observations sont souvent des vecteurs continus : l'utilisation de modèles à distributions discrètes implique donc une phase préalable de quantification de ces vecteurs, avec les dégradations qui en résultent. Il est dès lors intéressant d'inclure des densités d'observations continues dans les modèles de Markov. Néanmoins, afin de limiter le nombre de paramètres de ces distributions, il faut apporter quelques restrictions à la forme de ces densités de probabilité. La forme la plus commune de ces fonctions se présente comme une somme finie de gaussiennes, ou multi-gaussiennes. Ainsi les différents modèles présentés dérivant des modèles de Markov cachés sont utilisés pour modéliser des séquences d'observations. Ces dernières peuvent être de nature discrète (par exemples les caractères d'un alphabet fini) ou continue (fréquence d'un signal, température).

Jusqu'à présent, seuls des MMC modélisant des séquences d'observations discrètes ont été envisagés : ces observations prenaient des valeurs appartenant à un alphabet fini, et leurs probabilités étaient définies dans chaque état par un ensemble fini de valeurs. Le problème est que les observations sont souvent des vecteurs continus : l'utilisation de modèles à distributions discrètes implique donc une phase préalable de quantification de ces vecteurs [66]. Il est dès lors intéressant d'inclure des

densités d'observations continues dans les modèles de Markov. La probabilité d'émission d'une observation  $O$  au sein d'un état  $j$  devient donc :

$$b_j(O) = f(x) = \sum_{i=1}^M \pi_i f_i(x) \quad (\text{Eq. 2})$$

avec  $M$ : le nombre de composantes,  $\pi_i$   $i \in \{1...M\}$ : les probabilités de chaque composante et  $f_i(x)$ ,  $i \in \{1...M\}$ : les densités de probabilités de chaque composante. Ainsi, on cherche à décomposer une fonction inconnue et à priori complexe  $f$  sur un ensemble de fonctions plus simples  $f_i$ . On peut également décrire cette équation comme un modèle dans lequel on suppose que les données sont réparties aléatoirement (et indépendamment les unes des autres) en  $M$  classes qui sont caractérisées par une distribution  $f_i$  différente. Chaque composante  $f_i$  correspond à des lois normales multidimensionnelles.  $\mu_i$  et  $\Sigma_i$   $i \in \{1...M\}$ , sont les vecteurs moyens et les matrices de covariances de chaque composante. La fonction  $f_i$  de densité de probabilité gaussienne multidimensionnelle est donnée par :

$$f_i(x) = \frac{1}{(2\pi)^{\frac{p}{2}} \sqrt{|\Sigma_i|}} \exp\left[-\frac{1}{2}(x - \mu_i)^t \Sigma_i^{-1} (x - \mu_i)\right] \quad (\text{Eq. 3})$$

Où  $p$  désigne la dimension des vecteurs.

Concrètement, on calcule le modèle de Mélange de Gaussiennes pour chaque coefficient des vecteurs caractéristiques associés à un état. Par exemple, le MMC dans le cas d'observations continues en considérant qu'un seul coefficient, peut être modélisé de cette manière (voir figure 16):

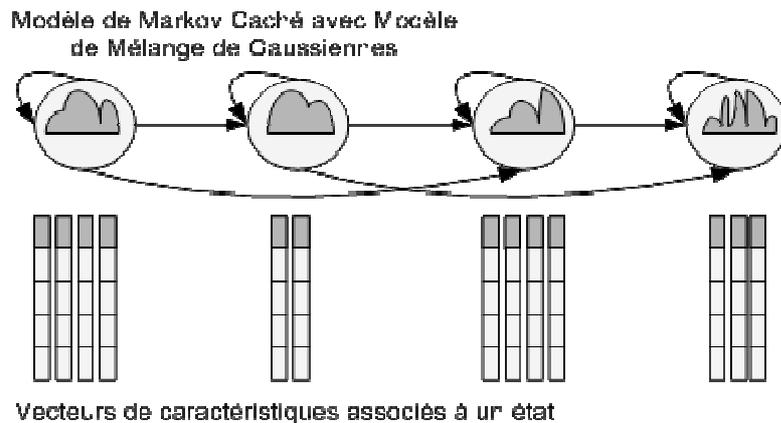


Figure 16. Modèle de Markov Caché en cas d'observations continues

La grande quantité de paramètres qui doivent alors être déterminés représente cependant un lourd handicap du modèle : si  $d$  est la dimension des vecteurs de primitives, l'estimation des

probabilités de génération  $P(O/S)$  nécessite, pour chaque état, la connaissance de  $(d^2+d+1) M$  paramètres, contre  $|\Sigma|$  dans le cas d'un alphabet fini.

#### 5.3.5.4. Le cas d'un MMC couplé (MMCC)

Un MMCC peut être considéré comme une collection de MMC, un pour chaque flux de données. Les nœuds cachés au temps  $t$  sont conditionnés par les nœuds au temps  $t-1$  de tous les MMC. Dans le MMCC, les variables interagissent avec leurs voisins. En plus chaque nœud possède sa propre observation. Le modèle couplé est donc, une représentation des dépendances conditionnelles entre les nœuds et leurs voisins les plus proches. Des MMC couplés ont permis de traiter simultanément des données audio et vidéo dans des problèmes de reconnaissance de texte audiovisuelle [76] ; les tâches de reconnaissance de la parole [77] et reconnaissance du langage des signes dans des vidéos [78]. Le modèle couplé présente une structuration parfaite des dépendances conditionnelles ce qui permet de représenter les différents composants d'une manière plus logique et surtout plus proche de la réalité. Les probabilités de transition, ainsi que les lois marginales sont calculables et permettent une décision Bayésienne plus exacte. Ainsi, ce graphe est une association du MMC avec une représentation des dépendances entre les voisins tout en gardant les caractéristiques du MMC toujours visibles. Après la construction du modèle, on doit définir les distributions de probabilités conditionnelles pour tous les nœuds, avec les mécanismes d'inférence et d'apprentissage. L'objectif de l'inférence est de calculer toutes les lois de probabilité marginales, et qui se base essentiellement sur l'approche Backward-Forward. Les MMC couplés sont utilisés lorsque l'on traite plusieurs sources d'observations de façon simultanée et que l'on veut prendre en compte les interactions entre les sources d'observations. Les techniques d'apprentissage dans les MMCC sont une extension des techniques d'apprentissage dans les MMC classiques.

#### 5.3.5.5. MMC triplet

Les modèles de Markov cachés, comme chaînes, champs ou arbres, admettent de multiples applications dans les domaines les plus variés. Dans de tels modèles la distribution a priori du processus caché est de Markov et la markoviénité à posteriori, indispensable pour les traitements, est obtenue grâce à des hypothèses fortes, et souvent irréalistes, sur le bruit. Cet écueil a été récemment contourné par l'introduction des modèles de Markov couple, dans lesquels on admet directement la markoviénité du couple (processus caché, processus observé). Bien que strictement plus général que le modèle caché, le modèle couple permet les mêmes traitements. Par ailleurs, les modèles triplets, obtenus à partir des modèles couple par l'introduction d'un processus latent, généralisent strictement des derniers et permettent encore les mêmes restaurations [79].

## 6. Etat de l'art des systèmes de détection et de prévision des changements

En domaine d'analyse spatio-temporelle, Lazri [80] a conçu un modèle d'analyse de données de précipitations par approche markovienne, les données utilisées sont constituées d'une série d'images collectées par le radar météorologique. Les résultats montrent que les précipitations sont bien décrites par les chaînes de Markov d'ordre supérieur aussi bien sur terre que sur mer et quel que soit le climat prévalant dans la région. En fouille de données agricoles, Mari [81] a développé un modèle markovien afin de comprendre et d'expliquer le processus qui produit les successions des cultures. L'auteur a utilisé la courbe de Peano [82] afin d'effectuer une segmentation spatiale en régions géographiques homogènes du point de vue des densités spatiales de cultures et ils ont employé les MMC d'ordre 2 pour étudier les suites de cultures. En reconnaissance d'images, Slimane [83] a conçu un algorithme hybride (AGUBW) pour l'apprentissage d'images par le MMC. Ainsi que Aurdal [84] a proposé une méthode de classification supervisée adaptée aux données de séquence d'images multi-temporelles LANDSAT. Ils ont développé une nouvelle méthodologie pour la classification du couvert végétal en intégrant les connaissances de la phénologie dans le processus de classification. La connaissance phonologique est représentée sous la forme d'un MMC. En traitement statistique des images, Pieczynski [85] a introduit des nouveaux systèmes dédiés à la segmentation d'images par les modèles des Markov tels que les chaînes de Markov triplet et les chaîne de Markov couple. Ces modèles sont strictement plus généraux que le modèle classique de chaîne de Markov cachée. Ils permettent notamment de mieux prendre en compte les frontières entre les classes, ce qui peut s'avérer d'un grand intérêt pour la segmentation d'images satellite. En contre partie, la complexité de ces modèles est supérieure à celle du modèle classique. Une application en détection des changements entre images radar a été développée par Carincotte [86] en se basant sur une segmentation markovienne floue d'images. Ce même genre d'idée a été repris dans ce travail Derrode [87]. Dans cet article, les auteurs ont conçu deux algorithmes de MMC; les MMC flous et les MMC sur une fenêtre glissante, les résultats sont intéressants mais pas entièrement convaincants. Dans le même domaine d'étude, Wijanarto [88] a conçu une technique Markovienne de détection des changements pouvant être utilisées pour prédire les changements futurs sur la base des taux de variation passé. L'idée est de générer des probabilités de changement entre les classes. Ces probabilités sont calculées à partir d'une matrice de transition de pixels entre les classes pour deux périodes de temps. C'est fondamentalement le même principe que la matrice croisée qui peut être utilisée pour l'évaluation de la précision. La diagonale de la matrice contient les pixels stables, tandis que les autres cellules contiennent des pixels changeants.

L'une des approches pouvant nous aider à concevoir une modélisation spatio-temporelle markovienne et celle qu'on a proposé dans un travail antérieur [89]. Cette approche utilise le RBD comme représentation des MMC hiérarchiques pour l'interprétation des images satellitaires en tenant compte de la composante temporelle. L'avantage de la représentation d'un MMC

hiérarchique par un RBD est la possibilité d'utiliser la procédure générique d'inférence et d'apprentissage de ces réseaux. De Plus, le temps de l'inférence dans un RBD est largement inférieur à celui dans un MMC. Mais en contre partie, ce système présente une grande complexité pour la définition de des différents niveaux du modèle et pour l'identification des liens (orientés) à ajouter entre les variables afin de capturer les dépendances entre les différents niveaux.

## **7. Discussion et conclusion**

Les travaux à base des MMC se prêtent davantage à l'utilisation des outils faisant appel aux mathématiques du calcul des probabilités, à la théorie des graphes (graphes orientés) et à l'algèbre linéaire (matrice de transition) et par conséquent, le modèle markovien permet une estimation rapide et une prédiction du futur. L'exploitation des MMC est souvent limitée au traitement d'images telle que la segmentation et, à l'extraction d'objet d'images telles que les techniques de détection de changements. Néanmoins, nous avons mené des travaux dans le domaine de la modélisation spatio-temporelle [90] [91], qui ont apporté des solutions intéressantes pour l'interprétation de la dynamique d'objets à partir des séries temporelles d'images satellite. Leur limite est qu'ils n'exploitent pas les techniques d'extractions d'informations. Cependant, ce domaine en plein essor avec le progrès de l'information proliférant sur la toile est un cadre tout à fait adéquat pour innover dans la représentation du contenu informationnel. L'extraction d'information consiste à reproduire une partie de l'information totale véhiculée par les données qui représente un intérêt particulier pour une application spécifique. Dans le cadre de notre étude, nous serons attentifs à ce que l'information extraite (descripteur: couleur, forme ou texture) soit la plus représentative du contenu informationnel véhiculé par les phénomènes spatio-temporels. L'exploitation des Séries Temporelles d'Images Satellitaires constitue un enjeu majeur pour un nombre grandissant de domaines d'application intéressés par la compréhension de l'évolution de la couverture terrestre. Nous voulons fournir une nouvelle méthodologie pour analyser et prévoir conjointement les nombreux événements spatio-temporels qui apparaissent dans les STIS. L'objectif est de créer une représentation des STIS qui soit compacte et qui décrive le contenu informationnel avec parcimonie. Cette représentation doit être universelle, c'est-à-dire qu'elle pourra être utilisée pour des applications dédiées à la compréhension telles que l'étiquetage automatique des structures spatio-temporelles, la découverte de nouveaux événements et la fouille d'information. Pour accomplir cet objectif, nous nous plaçons dans le cadre de deux domaines ; l'extraction d'information à partir des données brutes et l'analyse stochastique. Concernant la vision de l'extraction d'information, nous nous appuyons sur les outils de traitement d'images et les différents descripteurs d'une image satellitaire. Tandis que pour la modélisation stochastique, les MMC possèdent toutes les qualités pour représenter de manière générique la dynamique d'objets à partir d'une séquence d'images.

Nous contribuons à la proposition d'une approche originale; concevoir une méthodologie d'exploitation des STIS pour l'analyse spatio-temporelle à base d'un MMC en intégrant les techniques d'extraction d'informations. Nous allons ensuite décrire notre propre méthode d'interprétation des images satellitaires tout en passant par les différents appuis théoriques.

Pour la modélisation des données spatio-temporelles, on distingue deux familles de modèle: Les modèles déterministes et les modèles stochastiques; Un modèle est déterministe s'il ne fait pas appel au calcul de probabilités. Un modèle est stochastique s'il fait appel au calcul de probabilités. Le résultat prédit par un modèle déterministe est une conséquence directe des conditions initiales du modèle (les entrées déterminent la sortie). Le modèle stochastique est utilisé lorsque:

- les événements aléatoires jouent un rôle central dans le système à modéliser.
- un modèle déterministe ne peut décrire toutes les variations importantes des variables du système à modéliser

Dans notre contexte, nous nous intéressons à la modélisation stochastique car les connaissances manipulées par les systèmes intelligents en interprétation d'images sont généralement incertaines et imprécises. La prise en compte de ces critères constitue une évolution importante de ces nouveaux systèmes. L'incertitude est relative à la vérité d'une information qui caractérise sa conformité par rapport à la réalité. Elle exprime un doute sur la validité de l'information. L'imprécision concerne le contenu de l'information et porte sur un défaut quantitatif de connaissance. Elle peut représenter la difficulté rencontrée par les experts à exprimer clairement une information qui peut être à la fois incertaine et imprécise. Dans le contexte des données géographiques, ces caractéristiques sont présentes dans les images (incertitude) ou dans les données recueillies auprès des experts (incertitude, imprécision). Les causes d'incertitude proviennent généralement des défauts sur les capteurs, des mauvaises conditions de prise de vue, des données redondantes ou conflictuelles issues de différents capteurs et des opinions contraires données par les experts. La modélisation spatio-temporelle pour la prévision des changements en imagerie satellitaire fera l'objet du chapitre suivant.

# Modélisation spatio-temporelle à base de modèles de Markov cachés pour la prévision des changements en imagerie satellitaire

## 1. Introduction

Dans ce chapitre, nous proposons une nouvelle approche de modélisation spatio-temporelle à base d'un modèle de Markov caché (MMC) qui exploite une série d'images satellites en intégrant les techniques d'extraction d'informations. L'utilisation des MMC dans l'imagerie satellitaire est restée dédiée aux problèmes de segmentation et d'interprétation. Ces mêmes modèles sont utilisés pour la prévision mais dans d'autres domaines comme la reconnaissance de la parole et l'écriture, l'analyse des gestes. Dans ce travail, nous allons profiter du pouvoir prévisionnel des MMC pour l'exploiter dans le domaine de l'imagerie satellitaire.

Parmi les objectifs de la modélisation spatio-temporelle nous pouvons citer la recherche des objets intéressants dans la scène et ce à chaque instant de l'interprétation. La notion « objet intéressant » varie en fonction du but à atteindre et de l'état de l'interprétation. Ce qui permettra la reconnaissance des formes, la définition de modèles et la représentation des connaissances. L'interprétation des scènes est généralement considérée comme une transformation des données visuelles à travers différents niveaux d'abstraction. Cette transformation implique des connaissances différentes sur les données, les objets d'une scène, leurs caractéristiques et les traitements nécessaires aux différentes transformations élémentaires. Les données sont fournies directement par les capteurs optiques et radars.

## 2. Modélisation spatio-temporelle à base de modèle de Markov caché

Rappelons que l'objectif principal de cette étude est la modélisation spatio-temporelle à base de modèle de Markov caché pour le suivi d'objets en imagerie satellitaire. En d'autres termes, ayant une série d'images multi-dates représentant une même zone d'intérêt, nous cherchons à modéliser les variations entre ces images, par un modèle adéquat, à interpréter et à analyser ces variations pour pouvoir prédire les changements futures de cette zone. La réalisation de cet objectif passe par une chaîne de traitements (voir figure 17) et exige une élaboration substantielle à tous les niveaux: prétraitement, segmentation, reconnaissance et interprétation, donnant naissance à de nombreuses approches pour interpréter la dynamique de la scène [92].

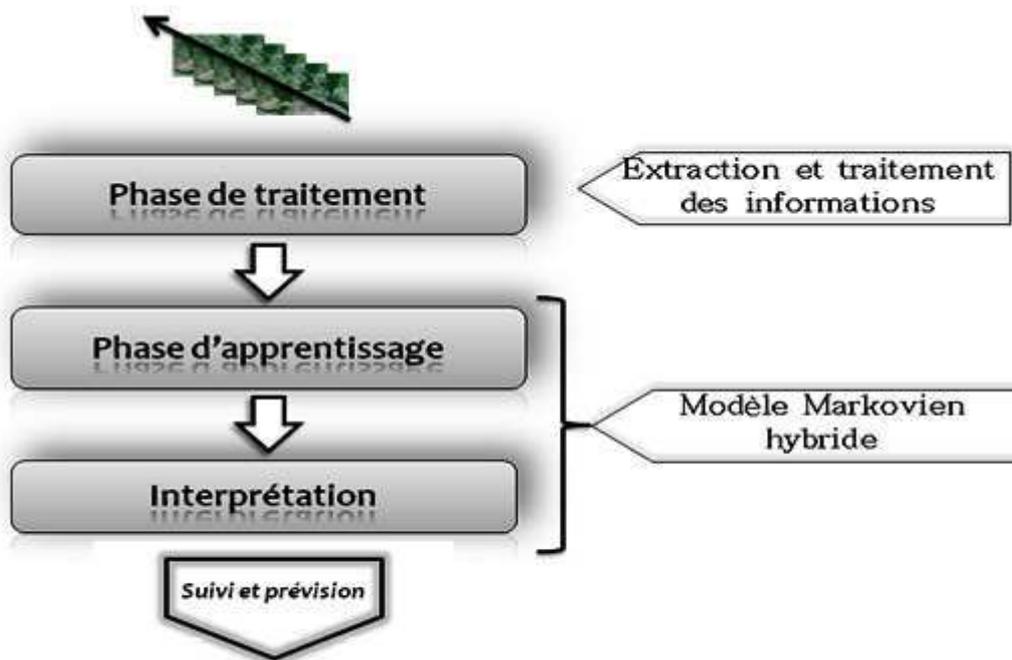


Figure 17. Architecture globale du Modèle proposé

## 2.1. La phase d'apprentissage

La séquence d'images multi-dates doit subir des corrections géométriques, radiométriques et atmosphériques pour pouvoir être exploitées. Ensuite, et afin d'extraire les zones pertinentes, sujets de suivi, il faut utiliser des algorithmes de segmentation d'images. Cela va permettre de calculer un vecteur de caractéristiques résumant l'information contenue dans l'image. Contrairement aux prétraitements, qui sont généralement mis en œuvre de manière standard (sans préjuger de l'application), l'exploitation numérique contient souvent des étapes d'amélioration guidées par un besoin thématique, conçues pour faciliter l'extraction d'un type d'information bien défini. L'interprétation d'images est donc la combinaison des deux à la fois. La détection de changements correspond à la détection et à la localisation de zones ayant évoluées entre deux observations (ou plus) d'une même scène. Ces changements peuvent être de différents types, d'origine et de durées variées, ce qui permet de distinguer les descripteurs selon l'application. Pour cela, nous pouvons nous servir de ses caractéristiques qualitatives, qui constituent des informations que l'on souhaiterait pouvoir évaluer, interpréter et prévoir sur le modèle final. Pour atteindre cet objectif, nous devons passer par une étape d'apprentissage qui consiste à estimer le vecteur paramètre  $\lambda$  du MMC sur la base d'un ensemble de séquences d'observations appelé corpus d'apprentissage. C'est une procédure de ré-estimation itérative des matrices  $A$ ,  $B$  et  $\Pi$  d'un MMC. On peut résumer le processus

global de cette section par la figure 18, en supposant que la base de descripteurs est déjà construite durant la phase précédente et contenant l'ensemble des vecteurs de données  $V$  décrivant chaque objet étudié à l'instant  $t$ :

$$V = [R_1 \text{ à } t_1, R_2 \text{ à } t_1, \dots, R_m \text{ à } t_1; \dots; R_1 \text{ à } t_n, R_2 \text{ à } t_n, \dots, R_m \text{ à } t_n]$$

Avec une classification non supervisée, on obtient un ensemble de classes  $C$  contenant les vecteurs déjà mentionnés :

$$C = [\text{Classe A} = \{\dots, \text{vecteur } X_i, \dots\}, \dots, \text{Classe Z} = \{\dots, \text{vecteur } Y_i, \dots\}]$$

L'utilisation d'un modèle de Markov caché nécessite des séries d'observations  $O$  préalablement calculées:  $O = (X_1, \dots, X_n)$ ; et un ensemble d'états cachés  $E = (Y_1, \dots, Y_m)$ , qui varie selon le domaine d'application. Pour ajuster les paramètres du MMC, on applique un apprentissage qui permet de générer les matrices d'émission et de transition. Pour généraliser à d'autres types de modèle, nous proposons la méthodologie suivante :

1. Identifier un ensemble d'états réels en observant l'objet extrait ;
2. Employer les descripteurs et filtrer les caractéristiques à partir des séquences d'images segmentées ;
3. Normaliser et enregistrer les vecteurs de données ;
4. Classifier ces données ;
5. Utiliser les états réels pour définir les états cachés, un modèle de transition initial et une distribution a priori sur les états ;
6. Apprendre le MMC pour ajuster ses paramètres.

Cette méthodologie nous a permis de construire des MMC de grande qualité pour une modélisation spatio-temporelle.

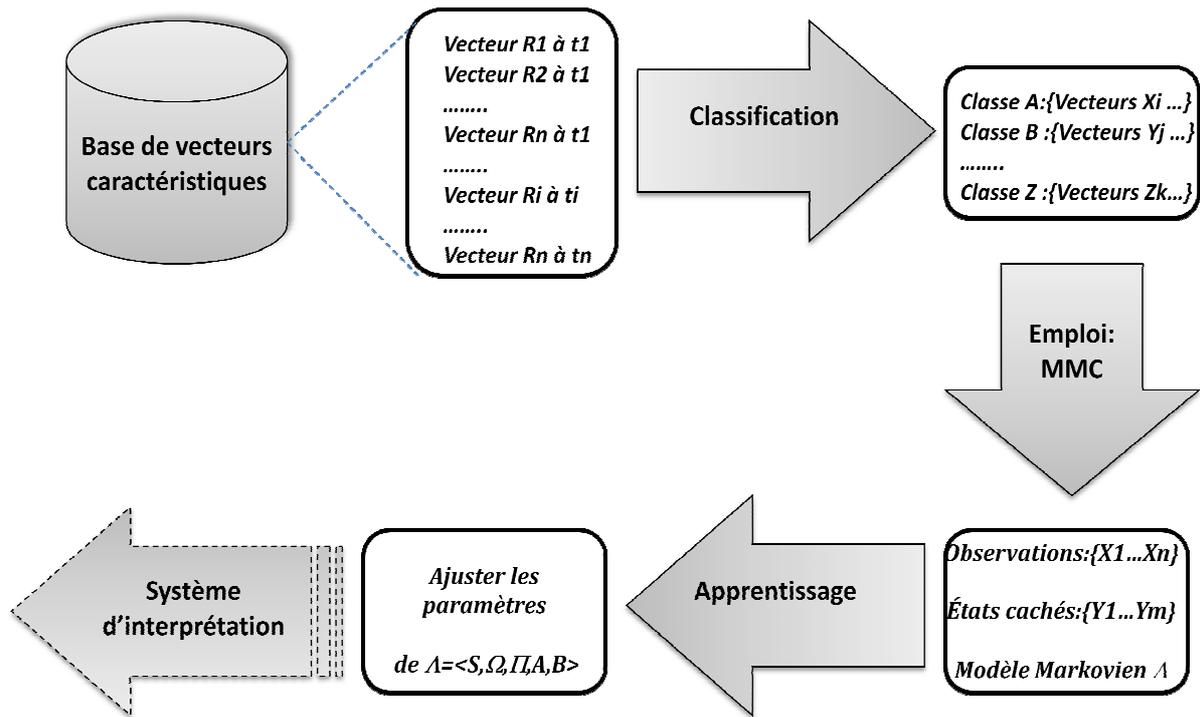


Figure 18. L'approche proposée pour l'apprentissage

## 2.2. La Phase de Suivi et de prévision

L'objectif de notre approche, est de suivre et prévoir les changements spatio-temporels des objets extraits à partir d'une séquence d'images satellitaires. Les MMC trouvent leur intérêt dans la résolution de trois problèmes qui sont l'évaluation, le décodage et l'apprentissage (voir figure 19). Etant données un MMC  $\lambda$  et une séquence  $O$  d'observations, nous cherchons à calculer la vraisemblance de cette séquence  $O$  avec le MMC  $\lambda$  (avec quelle probabilité le MMC  $\lambda$  engendre la séquence  $O$ ). Cette valeur est notée  $P(O=o | \lambda)$  qui peut être calculée par plusieurs algorithmes. Tandis que la reconnaissance consiste à trouver la séquence la plus probable d'état (caché) ayant conduit à la génération d'une séquence de sortie donnée et ce en appliquant un algorithme de reconnaissance.

## 2.3. Modélisation des données spatio-temporelle

Bien que l'approche proposée soit générique, l'extraction d'objets, sujet de suivi et de prévision, et le calcul des descripteurs, diffèrent selon le domaine d'application. Pour le cas de la végétation, par exemple, il est possible d'utiliser le NDVI, alors que dans le cas de l'urbain, il faut passer par le masque urbain.

### 2.3.1. Extraction des objets

Les mesures prises à partir de l'image segmentée permettent d'isoler dans l'image les objets à quantifier ou à reconnaître. Les mesures possibles sont très nombreuses et dépendent du problème posé et du type de segmentation. Les objectifs doivent être bien définis, au préalable, pour limiter le plus possible l'acquisition et la rendre efficace. Un descripteur est un vecteur de valeurs, calculé à partir d'une image, qui résume une information contenue dans l'image (la couleur, les gradients, la texture...). C'est une représentation de moins grande taille que l'image (quelques dizaines de dimensions au lieu de quelques centaines de milliers de pixels). Pour notre travail, la méthode commence par une chaîne de traitements qui commence par l'acquisition d'une série d'images satellitaires ( $I_1, I_2, \dots, I_n$ ) où  $I_j$  denote la  $j^{\text{ème}}$  image de taille  $M \times N$ . Chaque image est composée d'un ensemble de pixel représenté par un vecteur de  $n$  composantes  $x_j$ . A partir de ces vecteurs, on peut former la matrice  $S_{N \times M, n}$  des caractéristiques de l'image  $I$ . Nous procédons, par la suite, à une réduction de ces vecteurs. En plus, les images issues de différents capteurs et de différentes résolution, sont extrêmement corrélées. Ce qui nous permet de transformer la matrice  $S_{N \times M, n}$  en  $S_{N \times M, d}$  où  $d \ll n$  ( $d$  représente le nombre de descripteurs). Ces matrices sont ensuite, partitionnées par la SCFCM (spatially constrained fuzzy c-means algorithm [93]). C'est un algorithme basé sur l'optimisation d'un critère de classification quadratique, où chaque classe est représentée par son centre. SCFCM permet de réaliser une partition floue  $U_{N \times M, d} = (u_{ik})$ ,  $u_{ik}$  dans  $[0,1]$  de l'image à traitée. Plus précisément, soit  $V = \{V_i\}$  l'ensemble des centroides des classes,  $C$  le nombre de classes,  $n$  le nombre d'individus et  $m$  un facteur flou. L'objectif de la méthode est de trouver  $U$  et  $V$  qui minimisent la fonction du coût :

$$J_{SCFCM} = \sum_{j \in \Omega} \sum_{k=1}^C u_{jk}^m \|x_j - v_k\|^2 + \frac{\beta}{2} \sum_{j \in \Omega} \sum_{k=1}^C u_{jk}^m \sum_{I \in N_j} \sum_{m \in M_k} u_{im}^m \quad (\text{Eq. 4})$$

avec

$$\sum_{i=1}^c u_{ik} = 1 \quad \forall k = 1, \dots, n$$

$U$  et  $V$  sont calculés itérativement en utilisant:

$$u_{jk} = \frac{m(\|x_j - v_k\|^2 + \beta \sum_{I \in N_j} \sum_{m \in M_k} u_{im}^m)^{-1/(m-1)}}{\lambda_j} \quad (\text{Eq. 5})$$

$$\text{Et } V_i = \frac{\sum_{k=1}^n u_{ik}^m \mathbf{x}_k}{\sum_{k=1}^n u_{ik}^m} \quad (\text{Eq. 6})$$

et 
$$\lambda_j^{-1/(m-1)} = m \sum_{k=1}^C (||y_j - v_k||^2 + \beta \sum_{l \in N_j} \sum_{m \in M_k} u_{lm}^m)^{-1/(m-1)} \quad (\text{Eq. 7})$$

Où  $N_j$  est l'ensemble des voisins du pixel  $j$  et  $M_k = \{1, \dots, C\} \setminus \{k\}$ . Le paramètre  $\beta$  contrôle le compromis entre la minimisation de la fonction objectif de l'FCM standard, et l'obtention d'un lissage des éléments de la fonction [94]. SCFCM permet à chaque pixel  $i$  d'être représenté par un ensemble de  $C$  éléments  $u_{ij}$  décrivant le degré d'appartenance du pixel  $i$  à la région  $j$ ,  $1 \leq j \leq C$ . Le problème est que les vecteurs ne sont pas homogènes, les valeurs moyennes de ces deux éléments caractéristiques étant évidemment intrinsèquement différentes. Nous procédons donc préalablement à une normalisation de ces vecteurs, selon le schéma suivant :

- Pour chaque attribut  $j$ , rechercher parmi tous les points d'intérêts son maximum  $x_{j\text{-max}}$  et son minimum  $x_{j\text{-min}}$
- Pour chaque point d'intérêt  $i$ , modifier la valeur de l'attribut  $x_{ij}$ , en lui assignant la valeur  $x'_{ij}$ :

$$x'_{ij} = \frac{x_{ij} - x_{j\text{min}}}{x_{j\text{max}} - x_{j\text{min}}}$$

Ceci permet d'avoir tous les éléments du vecteur avec une valeur dans l'intervalle [0,1], et ayant tous par conséquent un poids équivalent. Chaque attribut est relatif à une caractéristique donnée (radiométrie, texture, géométrie, espace et contexte d'acquisition).

### 2.3.2. Extraction des vecteurs caractéristiques

La construction d'une base des caractéristiques à pour objectif d'estimer les paramètres du modèle. Une fois, la segmentation par SCFCM est appliquée, chaque image sera quantifiée, les objets isolés seront mesurés par les descripteurs choisis. Ces derniers seront collectés pour former la série des données brute de notre modèle Markovien. Pour cela les mesures prises seront enregistrés sous forme des vecteurs de valeurs décrivant chaque région de la zone d'étude à une date  $t$ . Ces vecteurs de données nous ont servi pour construire la base de données de notre modèle (voir figure 20). A partir de ces données brutes nous avons effectué un lissage sur les données de façon à obtenir des vecteurs caractéristiques de type géométriques [104], radiométriques ou spatiales.

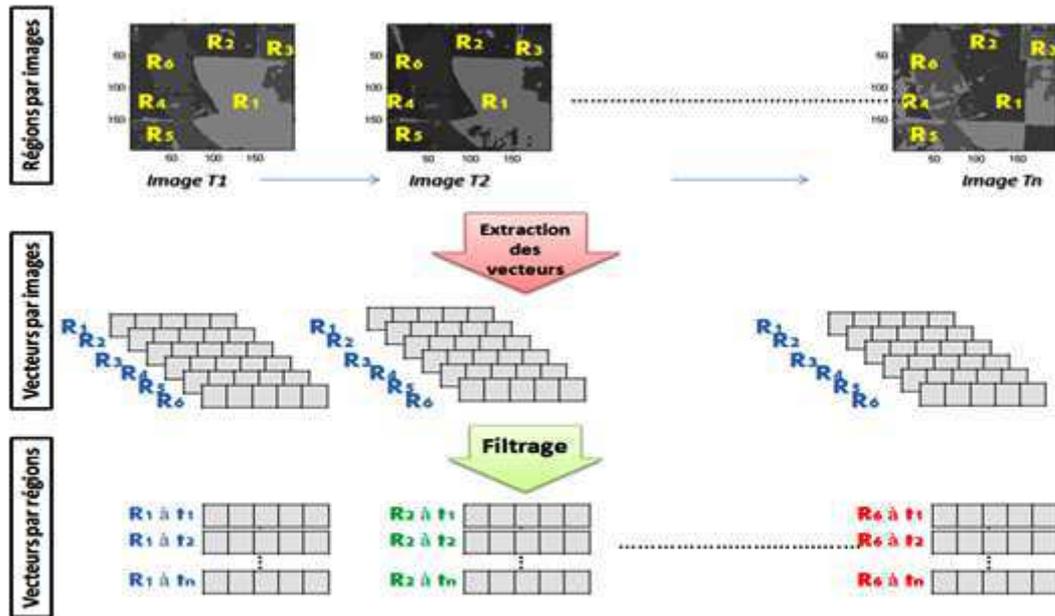


Figure 19. Une chaîne de traitement d'une image satellite

Jusqu'à présent, seuls des MMC modélisant des séquences d'observations discrètes ont été envisagés. Le problème est que les observations de notre étude sont des vecteurs continus. L'utilisation de modèles à distributions discrètes implique donc une phase préalable de quantification de ces vecteurs.

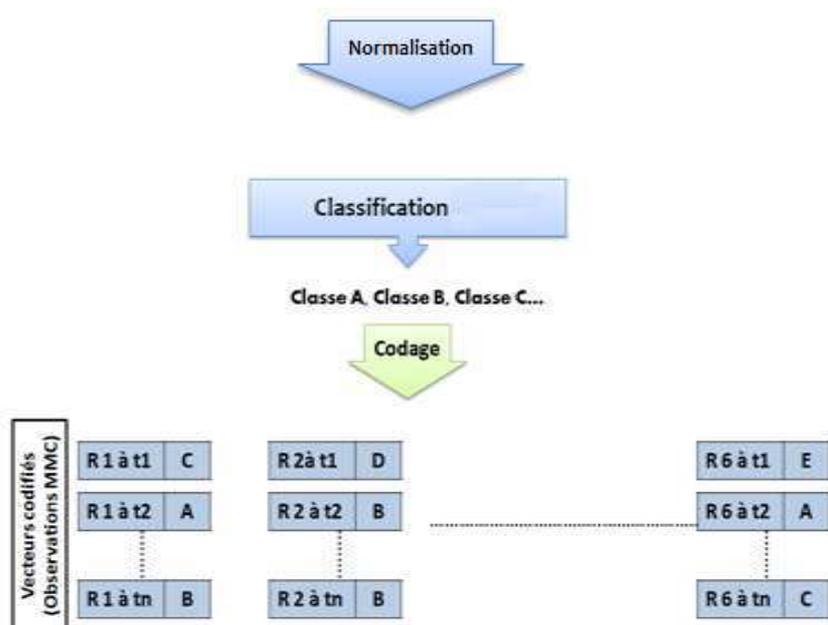


Figure 20. Construction des observations

Pour qu'on puisse employer un modèle à temps discret, ces vecteurs seront ensuite classés grâce à un classifieur non supervisé de façon à obtenir un espace d'observations discret (voir figure 20). On obtient donc un ensemble d'une dizaine d'observations possibles, par exemple pour un vecteur quelconque, on prend le sommet dans le paysage dont le vecteur caractéristique est le plus proche via une distance euclidienne.

### 3. Modèle de Markov caché hybride proposé

La modélisation markovienne d'un système aléatoire consiste d'abord en la construction d'une chaîne de Markov dont l'évolution de la chaîne représente l'évolution du système réel, afin de pouvoir en prédire le comportement et les performances. Ainsi, l'analyse markovienne d'une série d'observations aléatoire pendant une période fait apparaître l'existence de dépendances stochastiques; elle permet de constater la probabilité du passage d'un état vers un autre état à l'instant suivant. Autrement dit, tout système aléatoire peut être modélisé et analysé par la méthode des chaînes de Markov.

#### 3.1. Notation

Pour notre modèle, nous utilisons la notation suivante :

Le modèle  $\lambda = (A, B, \Pi)$  est décrit par trois matrices:

- $A = [..a_{ij}..]$  matrice de distribution des probabilités de transition entre états ;
- $B = [..b_j(k)..]$  matrice de distribution des probabilités de génération des symboles ;
- $\Pi = [..π..]$  matrice de distribution des probabilités initiales.

Notons :  $O = \{O_1, O_2, O_3, \dots, O_T\}$  la séquence d'observations pouvant être récupérée sur un processus. Pour construire un MMC, il est donc nécessaire de définir quels sont les états dans lequel le système peut être et quelles sont les observations possibles. On ne travaille pas sur les données brutes du système que l'on veut modéliser, il faut faire une étape de conception qui vise à bien définir le type de modèle que nous voulons construire. Ensuite on construira le modèle par apprentissage suivant l'algorithme utilisé pour ce type de modèle. Le MMC à construire est composé de deux parties distinctes, une chaîne de Markov à N états et un ensemble de M vecteurs de probabilités, chacun étant associé à chacun des états qui ne sont pas observables (ils sont cachés). Nous ne pouvons les étudier qu'en passant par les vecteurs de probabilités qui produisent les observations. On définit les éléments d'une chaîne de Markov cachée de la façon suivante:

- 1) N est le nombre d'états du modèle. Les états sont cachés et ne sont donc pas directement observables. On peut généralement passer d'un état à n'importe quel autre état du modèle. On définit les états du modèle comme étant  $S = \{S_1, S_2, \dots, S_N\}$ , et l'état au temps « t » comme étant

«  $q_t$  ».

2)  $M$  est le nombre d'observations différentes du modèle. On définit les observations comme étant  $V = \{V_1, V_2, \dots, V_M\}$ .

3) Les transitions entre états sont définies par la matrice de probabilité de changement d'états  $A = \{a_{ij}\}$  tel que

$$a_{ij} = P[q_t = S_j | q_{t-1} = S_i], \quad 1 \leq i, j \leq N, \quad a_{ij} \geq 0, \quad \sum_{j=1}^N a_{ij} = 1$$

4) La probabilité de la distribution des observations selon l'état « $j$ » est  $B = \{b_j(k)\}$

$$b_j = P[V_k \text{ au temps } t | q_t = S_j], \quad 1 \leq j \leq N, \quad 1 \leq k \leq M$$

5) L'état de départ se définit comme  $\pi = \{\pi_i\}$  tel que

$$\pi_{ij} = P[q_1 = S_i], \quad 1 \leq i \leq N,$$

### 3.2. Estimation des paramètres du modèle

Pour estimer et ajuster les différents paramètres de notre MMC, il faudra répondre à trois problèmes de bases soulevés par l'utilisation de ces modèles:

- Etant donné une séquence d'observations  $O = o_1 \dots o_T$  et un MMC  $H$ , comment évaluer efficacement  $P(O|H)$ , la probabilité d'observation de  $O$  étant donné  $H$  ?
- Etant donné une séquence d'observation  $O = o_1 \dots o_T$  et un MMC  $H$ , comment choisir une séquence d'états  $s_1 \dots s_T$  optimale dans un certain sens (i.e. expliquant au mieux  $O$ ) ?
- Comment ajuster les paramètres d'un MMC  $H$ , pour maximiser  $P(O|H)$  ?

Le premier problème est un problème d'évaluation, qui peut également être vu comme un problème d'estimation de la capacité d'un modèle donné à reconnaître une séquence d'observations donnée. Le second problème se ramène à l'idée de dévoiler les états cachés  $S$ , sans y avoir accès directement. Enfin, le troisième problème se ramène à l'apprentissage du modèle par des séquences d'observations, en vue d'optimiser ces paramètres pour un problème spécifique donné.

Les deux premiers problèmes concernent l'explication et l'évaluation du modèle et utilisent respectivement l'algorithme Forward-Backword et l'algorithme de Viterbi pour cela. Ces deux algorithmes supposent disposer d'un MMC construit et paramétré de manière à modéliser de façon satisfaisante les séquences à traiter. La question au centre de ce paragraphe est celle de la détermination des paramètres de ce modèle. Dans la plupart des applications, ces paramètres doivent être construits à l'aide d'un algorithme d'apprentissage. Ces algorithmes sont appliqués sur un ensemble de séquences représentatives des séquences que l'on souhaite modéliser et appelées

séquences d'apprentissage. On peut distinguer dans le problème de l'apprentissage d'un MMC deux cas de figure distincts, suivant que la structure (nombre d'états du MMC et transitions autorisées) est connue ou ne l'est pas. Lorsque la structure est connue, le problème se réduit à un problème d'entraînement consistant à estimer les paramètres numériques (distributions de probabilité de première visite, de transition et de génération) de manière à expliquer au mieux les séquences d'apprentissage. Pour certaines applications, on ne dispose pas de connaissances suffisantes pour inférer naturellement la structure du MMC. L'apprentissage devient alors encore plus difficile. Il ne suffit plus de paramétrer une structure mais il faut également déduire cette structure des exemples fournis.

On souhaite donc, entraîner un MMC à partir d'une structure connue. On dispose pour cela d'un ensemble d'apprentissage composé de séquences supposées représentatives des séquences que l'on souhaite modéliser. Une approche possible est, suivant le principe du maximum de vraisemblance, de chercher les paramètres  $\lambda = \langle \pi, A, B \rangle$  du MMC qui maximisent la probabilité de génération des séquences d'apprentissage. Soit  $O = \{O_1 \dots O_K\}$  l'ensemble des séquences d'apprentissage. On suppose que ces séquences sont indépendantes et donc que la probabilité de générer l'ensemble d'apprentissage est simplement le produit des probabilités de génération de chacune des séquences. L'objectif est alors de trouver les paramètres  $\lambda = \langle \pi, A, B \rangle$  maximisant :

$$P(O | H) = \pi P(O^k | H) \quad (\text{Eq. 8})$$

Une approche alternative au principe du maximum de vraisemblance est de chercher à maximiser la probabilité de génération des séquences d'apprentissage suivant leur chemin de Viterbi. Le but est alors de trouver les paramètres  $\hat{\lambda} = \langle \pi, A, B \rangle$  maximisant :

$$P(O | H) = \pi P(O^k | H, V^k), \quad (\text{Eq. 9})$$

où  $V^k$  est le chemin de Viterbi de la séquence  $O^k$  dans  $H$ , et  $V = \{V^1 \dots V^K\}$ . Les paramètres ne sont donc pas estimés en maximisant la vraie probabilité de génération des séquences d'apprentissage mais la probabilité de génération suivant les chemins les plus probables. Cette approche peut sembler moins rigoureuse que l'approche basée sur le principe du maximum de vraisemblance, mais elle est très utilisée en pratique et possède quelques arguments en sa faveur, en particulier celui selon lequel la probabilité de génération d'une séquence de symboles suivant son chemin de Viterbi est en général beaucoup plus élevée que suivant n'importe quel autre chemin. Cette observation a conduit à l'hypothèse, appelée hypothèse de Viterbi, que tous les chemins, excepté le chemin de Viterbi, ont une probabilité nulle ou négligeable d'engendrer la séquence. Sous cette hypothèse, la probabilité de génération d'une séquence  $O^k$  par un MMC  $H$  peut être approximée par la probabilité de génération de  $O^k$  suivant son chemin de Viterbi dans  $H$ . Nous avons alors :  $P(O | H) \approx P(O | H, V)$ . Suivant la méthode d'estimation des paramètres choisie, il existe deux heuristiques permettant l'entraînement des MMC. Ces deux algorithmes, très similaires, sont tous deux issus

d'une méthode générale servant à l'estimation des paramètres d'une grande famille de modèles probabilistes et appelée algorithme d'Expectation-Maximization (EM). Il existe un cas où il est possible de paramétrer la structure du MMC de manière à maximiser  $P(O|H)$  de manière optimale. Ce cas est celui rencontré lorsque l'on connaît les chemins de Viterbi des séquences d'apprentissage dans la structure. En effet, on peut alors associer à chaque état, chaque transition et chaque symbole attaché aux états du MMC le nombre de fois où ils sont utilisés pour générer l'ensemble d'apprentissage.

Soit  $n_s$ ,  $n_{s \rightarrow s'}$  et  $n_s^o$  respectivement le nombre de fois où l'état  $s$  est utilisé, le nombre de fois où la transition  $s \rightarrow s'$  est utilisée et le nombre de fois où le symbole  $o$  est généré par l'état  $s$  dans les chemins de Viterbi. Alors l'équation  $P(O|H)$  peut être réécrite :

$$P(O/H, V) = \prod_{s \in S} (\prod_{o \in \Sigma} [P(o/s)]^{n_s^o}) \prod_{s' \in S} P(s \rightarrow s')^{n_{s \rightarrow s'}} \quad (\text{Eq. 10})$$

Maximiser cette formule revient à maximiser indépendamment chacun de ses sous-produits. Les estimateurs de  $A$  et  $B$  recherchés se calculent donc par :

$$P(s \rightarrow s') = n_{s \rightarrow s'} / n_s \quad \text{et} \quad P(o/s) = n_s^o / n_s$$

Cette méthode d'estimation n'est possible que dans le cas favorable où les chemins de Viterbi sont connus. Lorsque ce n'est pas le cas, le problème est évidemment plus difficile et l'algorithme d'entraînement de Viterbi peut alors être une solution : c'est une méthode de réestimation itérative qui consiste, à partir d'un paramétrage initial du MMC, à calculer les chemins de Viterbi des séquences d'apprentissage à l'aide de l'algorithme de Viterbi. Les chemins de Viterbi sont utilisés pour calculer le nombre de fois où chaque transition, chaque état et chaque symbole attaché aux états est utilisé. On réestime alors à l'aide des formules précédentes les paramètres du MMC, nous paramétrons de nouveau, la structure à l'aide de ces estimations et nous réitérons la procédure jusqu'à stabilité. Nous pouvons montrer que  $P(O|H, V)$  augmente à chaque itération et que l'algorithme converge vers un optimum local. Malheureusement, il existe généralement un grand nombre d'optima locaux et le paramétrage obtenu par ce processus dépend fortement du paramétrage initial choisi.

L'algorithme d'entraînement de Baum-Welch est un algorithme qui cherche à estimer les paramètres  $\hat{\lambda} = \langle \pi, A, B \rangle$  du MMC en maximisant l'équation 8 (Eq. 8). C'est un algorithme de réestimation itératif qui fonctionne sur le même principe que l'algorithme d'entraînement de Viterbi. Dans ce dernier, nous comptons le nombre de fois où chaque état, chaque transition et chaque symbole attaché aux états est utilisé dans les chemins de Viterbi. Ici nous voulons maximiser les probabilités de génération réelles, et non celles des chemins les plus probables. Nous associons aux états, aux transitions et aux symboles le nombre de fois où ils sont utilisés pour toutes les séquences et tous les chemins susceptibles de générer les séquences, pondéré par la probabilité du

chemin. Ces comptes pondérés sont alors utilisés pour ré-estimer les paramètres du modèle de la même manière que pour l'algorithme d'entraînement de Viterbi.

### 3.3. Les techniques utilisées

- Pour la réduction de vecteurs caractéristiques, nous allons utiliser la méthode de l'analyse des composantes principales (ACP) qui est une technique très utilisée en matière de télédétection. En plus, les images issues de différents capteurs, donc de différentes résolution, sont extrêmement corrélées. L'objectif de l'ACP est de compresser les données originales en groupes de façon à maximiser la variance des données.

- L'algorithme d'apprentissage choisi est l'algorithme de Baum-Welch, c'est le plus communément utilisé, lequel est une instance d'algorithmes EM appliquée aux MMC. Il se fonde sur le critère du Maximum de Vraisemblance. Etant données un MMC  $\lambda$  et une observation  $O$ , nous cherchons le MMC  $\lambda^*$  qui a la plus forte probabilité d'engendrer la séquence  $O = \{O_1, O_2, O_3 \dots O_T\}$ .

- Le classifieur non supervisé retenu est un réseau de Kohonen [96], et cela pour son efficacité et sa simplicité d'implémentation. Les réseaux de Kohonen sont composés d'une grille de neurones (ou nœuds, ou unités) auxquels seront présentés des stimuli. Un stimulus est un vecteur, de dimension  $d$ , qui décrit un objet à classer. Ce vecteur peut aussi bien être une description des caractéristiques physiques des objets stimuli qui fait référence à des caractéristiques, telle que la présence ou l'absence d'un mot-clé dans un document. Chaque unité de la grille est reliée au vecteur d'entrée (stimulus) par l'intermédiaire de  $d$  synapses de poids  $w$  (Figure 21). En fait, à chaque unité est associé un vecteur de dimension  $d$  qui contient les poids  $w$ .

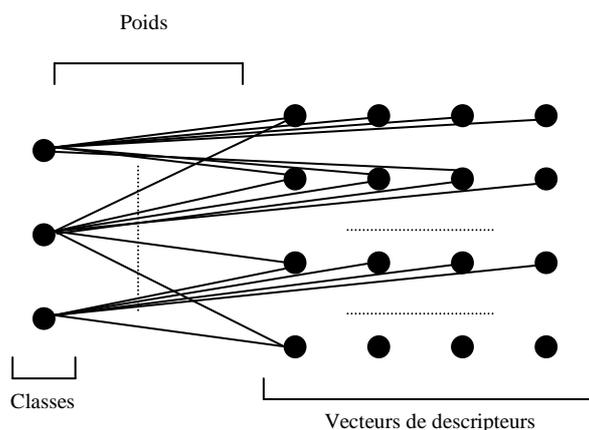


Figure 21. Schéma d'une carte de Kohonen connectée à un stimulus (les connexions sont complètes)

Représentons maintenant l'algorithme d'apprentissage d'une carte de Kohonen. En premier lieu, la grille doit être initialisée de manière aléatoire. Un cycle d'apprentissage est constitué des étapes suivantes :

- 1) Présenter un vecteur d'entrée associé à un stimulus à la grille.
- 2) Trouver le nœud gagnant (ou *winner*) : C'est l'unité dont le vecteur associé est le plus similaire au vecteur d'entrée.
- 3) Modifier les poids  $W_i$  du nœud gagnant, ainsi que ceux de son entourage, de manière à ce que les vecteurs associés (les vecteurs de poids) «se rapprochent d'avantage» du vecteur d'entrée présenté à la grille. La règle de modification est la suivante :

$$w_i(t+1) = w_i(t) + h(r,t)(p_i - w_i(t)) \quad \text{si } i \in \text{voisinage}$$

$$w_i(t+1) = w_i(t) \quad \text{si } i \notin \text{voisinage}$$

avec  $h(r,t) = \alpha(t) \cdot v(r)$  ( $\alpha(t)$  : Le taux d'apprentissage et  $v(r)$  : la fonction de voisinage)

- 4) Faire décroître la taille de la zone de voisinage des nœuds gagnants (la zone qui contient les neurones subissant la transformation).
- 5) Faire décroître le coefficient d'apprentissage,  $\alpha(t)$ , qui contrôle l'importance des modifications appliquées aux vecteurs de poids.
- 6) Arrêter l'apprentissage si le coefficient d'apprentissage est nul, sinon, présenter un autre stimulus à la grille.

La modification des vecteurs associés aux unités se fait de manière différente selon la position des nœuds par rapport à l'unité gagnante. Le nœud gagnant sera celui dont le vecteur subira le plus de modifications, tandis que les unités les plus éloignées seront moins affectées. La fonction de voisinage  $v(r)$  va être maximale pour  $r=0$  et décroître quand  $r$  croît (quand on s'éloigne du nœud gagnant). Une fonction couramment employée est la courbe gaussienne.

Concernant le système général d'analyse spatio-temporel, il est présenté dans la figure 22. Il comporte trois modules. Le premier module fait le traitement d'image, le deuxième se charge de l'apprentissage et le troisième s'intéresse à l'interprétation. Concernant les traitements subis par une image satellitaire sont résumés dans la figure 23.

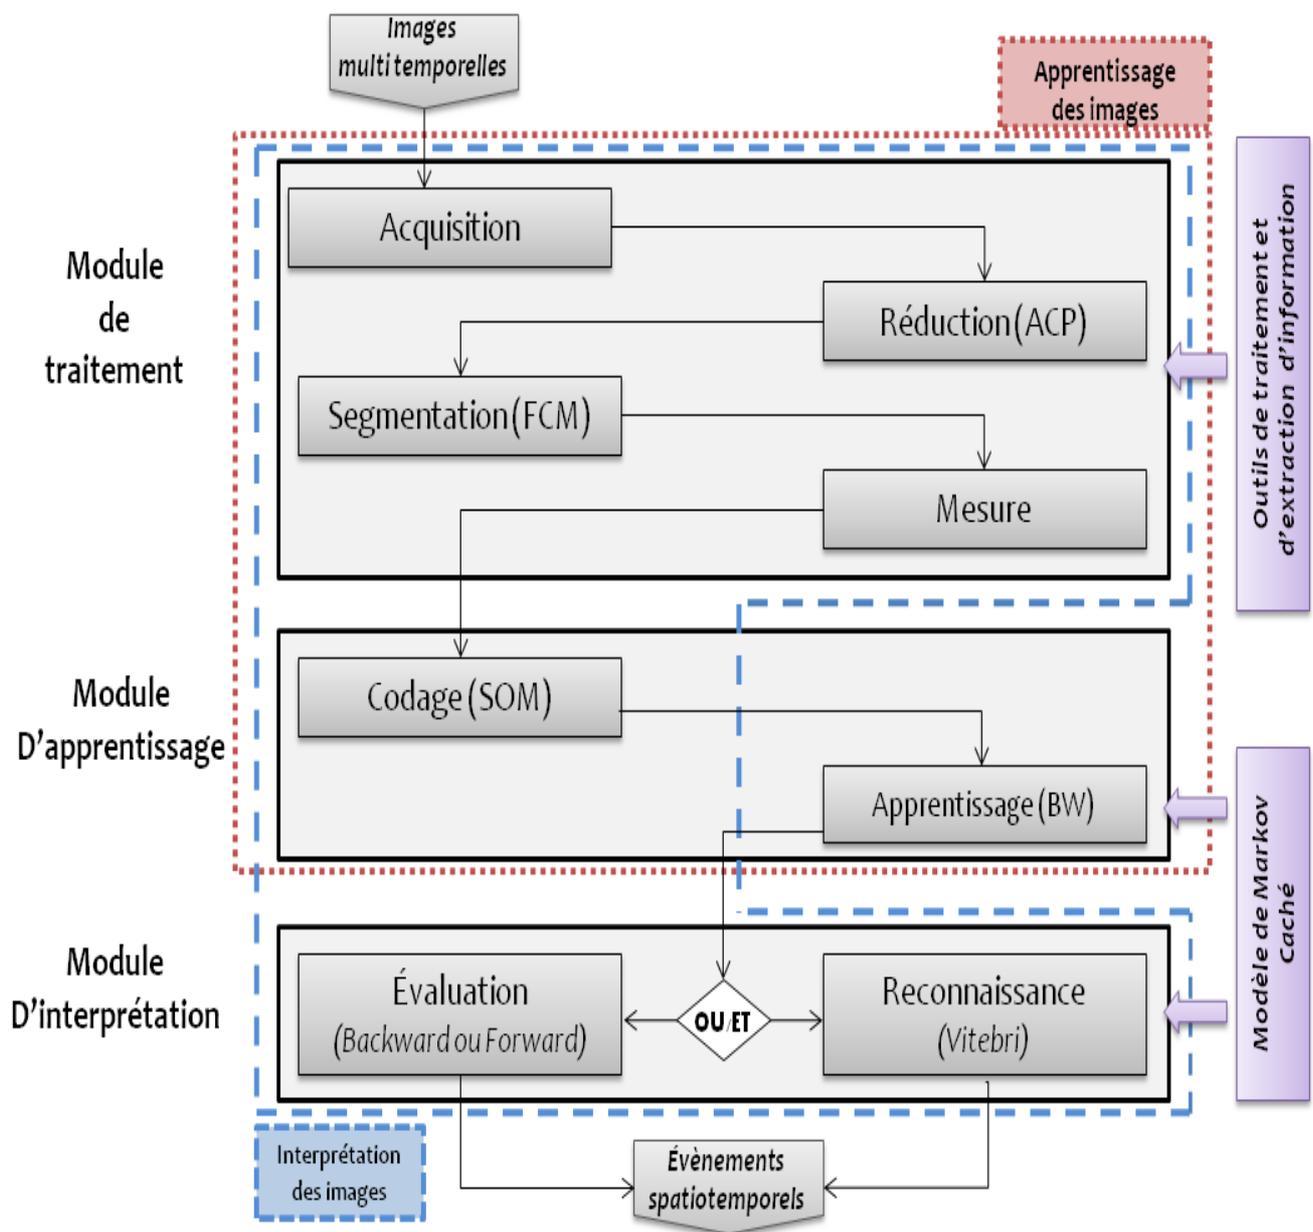


Figure 22. Système d'analyse spatio-temporelle



- **Critique** : c'est l'état de la végétation lorsque sa surface devient inférieure à 50% de la surface initiale.

Il faut noter que la surface initiale est définie par la surface de la végétation correspondante à la première image dans l'ordre chronologique de la série. Cette surface sera mise à jour si nous rencontrons dans la série d'images une surface plus grande.

Chacun de ces trois états peut avoir deux instances différentes relatives à la vitesse de la variation de la surface. Cette vitesse est définie par la variation de la surface à l'instant sélectionné par rapport à la surface à l'instant précédant. Nous définissons ainsi les deux instances suivantes :

- **Normale** : lorsque la variation est inférieure à 10% de la surface de la végétation à l'instant précédant et la surface de la végétation saine n'a pas diminué.
- **Alarmante** : lorsque cette variation est supérieure à 10% de la surface de la végétation à l'instant précédant ou la surface de la végétation saine a diminué.

$V_v$ ,  $TV_v$  et  $V_{vs}$  sont respectivement les descripteurs de la variation de la végétation, de la vitesse de cette variation et la variation de la végétation saine.

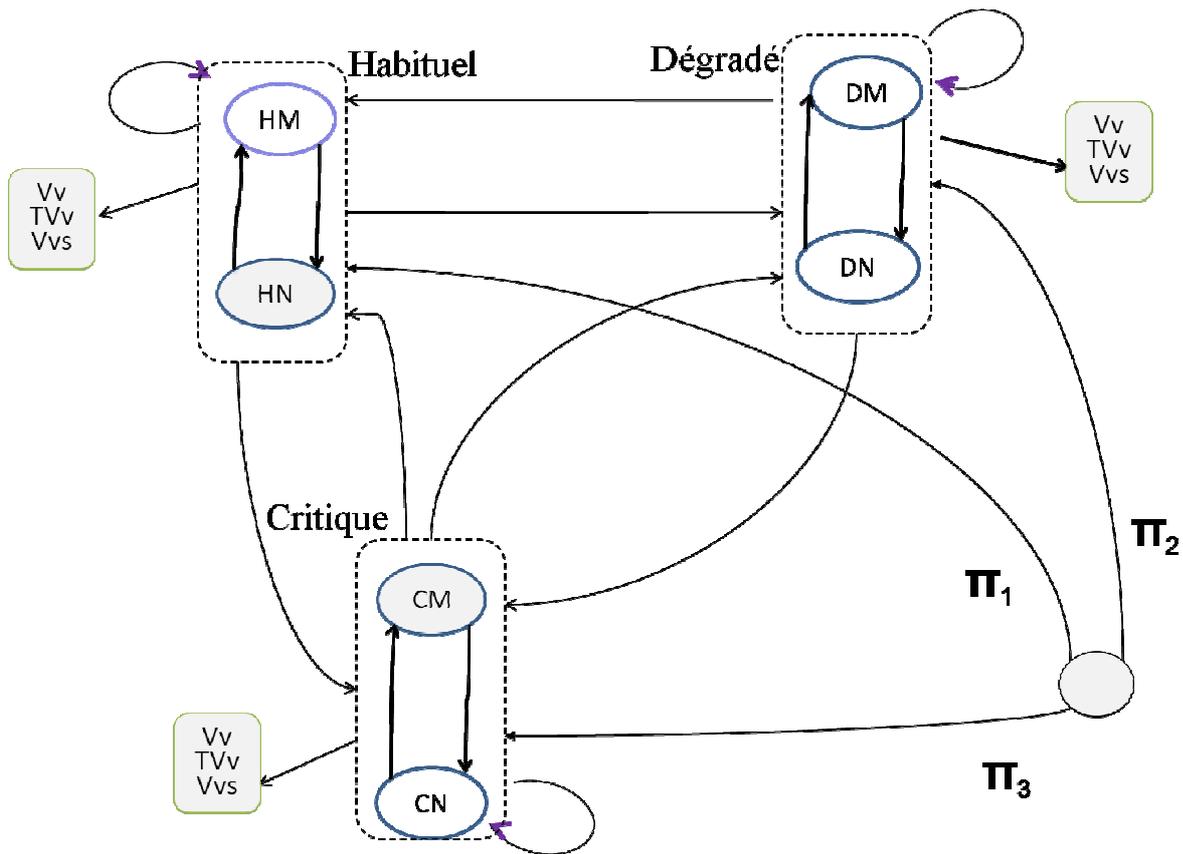


Figure 24. Structure du modèle de végétation

Les arcs orientés reliant les différents états représentent les transitions d'un état à un autre, cette transition peut se produire à partir de l'une des deux instances appartenant à cet état. Les flèches

sortantes de chaque état représentent les émissions ou les observations émises par cet état et résumées par les descripteurs de changement.

#### 4.2. Formalisation du modèle au cas de l'urbain

Dans le cas où nous disposons de deux sources d'observations, nous utilisons le modèle de Markov caché couplé (MMCC). La modélisation d'un MMCC comprend deux sources d'observations, une pour les observations  $y^1_{1:T}$  et une autre pour les observations  $y^2_{1:T}$  permettant de modéliser les interactions entre deux MMC de type left-to-right décrivant ces sources d'observations. Ici, les interactions sont telles que l'état à un instant  $t$  de l'un des deux MMC est fonction de l'état à l'instant  $t-1$  des deux MMC. Les probabilités d'émission associées à ces modèles sont de la forme  $p(x_{t+1}|x_t, y_t)$  et  $p(y_{t+1}|x_t, y_t)$ . La principale problématique, avec les MMC couplés, est le temps de calcul important pour l'entraînement des modèles. Les temps de calcul, important avec deux processus (tels que celui présenté dans la figure 25), deviennent ingérables en considérant plus de deux processus.

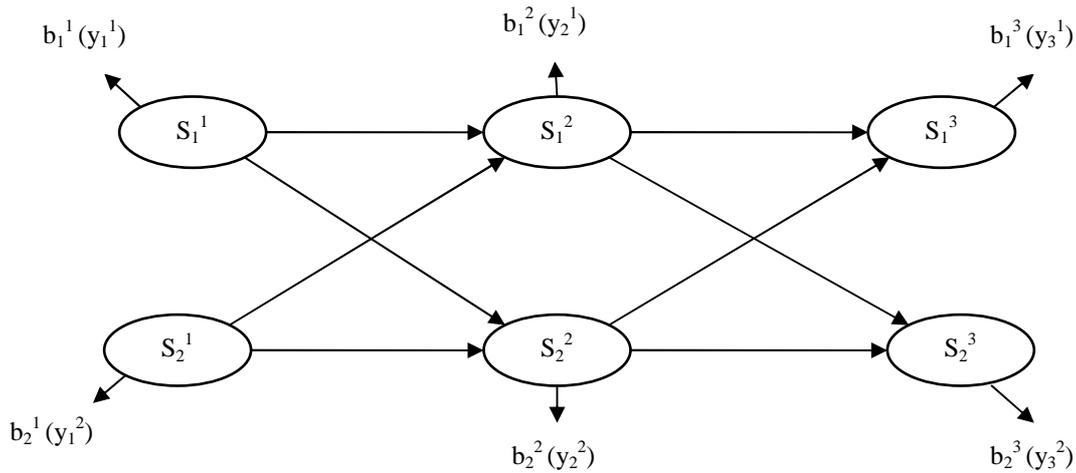


Figure 25. Un modèle de Markov caché couplé avec 2 chaînes

Les éléments d'un MMCC sont:

- Les probabilités initiales :

$$\pi = \{\pi_j^{(c)}\}, 1 \leq c \leq C, 1 \leq j \leq N^{(c)} \text{ Avec } \sum_{j=1}^{N^{(c)}} \pi_j^{(c)} = 1$$

- Les probabilités de transition :

$$A = \{a_{ij}^{(c,c)}\}, 1 \leq c', c \leq C, 1 \leq i \leq N^{(c')}, 1 \leq j \leq N^{(c)} \text{ avec } \sum_{j=1}^{N^{(c)}} a_{ij}^{(c',c)} = 1$$

- Les probabilités d'observations :

$$B = \{b_j^{(c)}(k)\}, 1 \leq c \leq C, 1 \leq j \leq N^{(c)}, 1 \leq K \leq M \text{ avec } \sum_{k=1}^M b_j^{(c)}(k) = 1$$

- Coefficient de couplage :

$$\theta = \{\theta_{cc'}\}, 1 \leq c', c \leq C \text{ avec } \sum_{c'=1}^C \theta_{cc'} = 1$$

$k_j$  indique le chemin associés à l'état  $i$  en  $t$  pas de temps, et  $c$  désigne une matrice de couplage. La matrice de transition de la première chaîne est représentée par un  $\alpha$  et la matrice de transition de la deuxième chaîne par un  $\alpha'$ .

Pour un MMCC avec deux chaînes l'algorithme forward comporte les étapes ci-dessous :

- Calculer tous les variables avant  $p_{t+1}(i)$

$$p_t(j) = \left[ \sum_i \alpha_{ij} c_{k_{j,t-1}} \alpha_{t-1}^*(i) \right] b_j(o_t)$$

- Choisir l'un des meilleurs chemins de chaque chaîne

$$k_{j,t} = \arg \max_i (p_t(i))$$

- Calculer le variable  $\alpha$  avant pour chaque chemin d'accès dans l'ensemble du modèle, cette variable est utilisée pour propager des probabilités:

$$\alpha_t^*(j) = b_j(o_t) \sum_i \alpha_{ij} c_{ik_{j,t}} c_{k_{i,t-1}j} \alpha'_{k_{i,t-1}k_{j,t}} \alpha_{t-1}^*(i)$$

- Marginalisé sur chaque tête sur tous les chemins possible obtenir la variable avant dans chaque chaîne. Cette variable est utilisée pour les paramètres de ré-estimation

$$\alpha_t(j) = b_j(o_t) \sum_i \alpha_{ij} c_{k_{i,t-1}j} \sum_g b_{k_{g,t}}(o_t) c_{jk_{g,t}} \alpha'_{k_{i,t-1}k_{g,t}} \alpha_{t-1}^*(i)$$

Les variables en arrière sont calculés de manière similaire que les variables en avant en utilisant le chemin dans l'algorithme de l'avant. L'algorithme Viterbi travaille également de la même manière mais il utilise une maximisation sur les chemins précédente au lieu d'une sommation. Dans cet algorithme, chaque tête peut avoir un chemin différent.

$$P(q_t' = i, q_{t-1} = j | o) = \frac{\alpha_{j,t-1} c_{q_t'=i}(o_t) \beta_{i,t}}{P(o)}$$

$$\hat{c}_{i'j} = \frac{\sum_{t=2}^T P(q_t' = i, q_{t-1} = j | o)}{\sum_{t=2}^T \alpha_{j,t-1} \beta_{j,t-1}}$$

Les MMCC couplés sont utilisés lorsque l'on traite plusieurs sources d'observations de façon simultanée et que l'on veut prendre en compte de possibles interactions entre les sources d'observations. Or, dans notre contexte nous pouvons suivre, par exemple, la croissance urbaine par différentes sources d'observations : une source concerne les descripteurs de l'image et d'autres vont présenter des indicateurs spécifiques à décrire la croissance urbaine comme la pression démographiques, les facteurs économiques, le plan d'aménagement urbain, le schéma directeur

d'aménagement, le plan des zones inondables, la liste des zones archéologiques. Notre modèle générique modélise la croissance urbaine en fonction de  $n$  sources qui contiennent des informations multi-dates de  $\{1...m\}$ . En pratique nous allons modéliser chaque source par un MMC. Mais il faut définir une table de couplage entre ces sources. C'est le cas lorsqu'on vise à isoler la zone d'intérêt, qui sera dans notre cas, le masque urbain, du reste de la scène. Et ce dans le but de détecter le changement qu'a subit cette zone entre les différentes images composant la séquence d'images multi-dates ; afin de pouvoir modéliser et suivre ces variations. Le masque urbain est pour la plupart des géographes, la plus petite surface connexe englobant toutes les surfaces bâties. Cela dit, cette définition est relativement variable dans la mesure où de subtiles distinctions interviennent sur ce que l'on appelle le bâti. Suivant les urbanistes, elle inclut la frange péri-urbaine où elle l'exclut. Un masque urbain est également dépendant de la notion de densité que l'on emploie et donc sa limite inférieure. Sa bonne définition est essentielle pour tout travail de classification ou d'automatisation d'étude urbaine dans la mesure où cette propriété de connexité apporte une information essentielle. En effet, sans cette propriété, il sera très difficile par exemple de distinguer les parcs boisés des forêts extérieurs à la ville [94] [95]. Cette étape passe nécessairement par trois phases :

- Extraction des caractéristiques qui consiste à calculer des mesures sur la texture ou à construire une image par transformation locale ;
- Classification qui permet d'associer à chaque pixel ou à chaque région formées de pixels connexes une classe (en l'occurrence la classe bâti ou la classe non bâti) ;
- Regroupement qui permet d'obtenir le masque urbain en regroupant les pixels connexes ou les régions connexes classées en bâti.

Puisque nous travaillons dans un cadre générique, nous faisons le choix d'utiliser la méthode d'extraction de masque urbain basée sur les indices d'Haralick car on peut l'appliquer à tous les types d'images. L'indice d'Haralick utilisé dans notre cas est l'entropie qui correspond à une mesure du désordre de la matrice de cooccurrence elle est maximal quand toutes les valeurs sont égales.

$$H_{s,d} = \sum_i \sum_j (C_s(i, j, d) * \log(C_s(i, j, d)))$$

Avec  $C_s(i, j)$  est la probabilité d'apparition du couple  $(i, j)$  au pixel  $(i, j)$  et  $d$  le système de voisinage. La méthode consiste d'abord, à créer l'image de texture où chaque pixel contient la valeur d'entropie dans un système de voisinage  $9*9$ , puis segmenter cette image en utilisant un seuil égale à 0.8 parce qu'il est à peu près la valeur de l'intensité des pixels correspondant dans l'image et enfin on extrait le masque urbain. Pour mesurer l'évolution du masque entre deux dates, il faut utiliser des descripteurs spécifiques aux images satellitaires qui seront par la suite, l'entrée pour l'estimation des paramètres de notre modèle MMCC. Dans notre cas nous allons utiliser les relations spatiales,

l'information texturale et l'information géométrique. Pour suivre l'expansion urbaine entre deux images bi-dates de la même zone d'intérêt, et puisque le masque urbain n'évolue pas de la même façon dans toutes les directions, alors on vise à modéliser chaque direction à part [97]. D'où, nous allons diviser le masque urbain en quatre parties selon la direction (nord-ouest, nord-est, sud-ouest et sud-est) comme l'indique la figure 26.

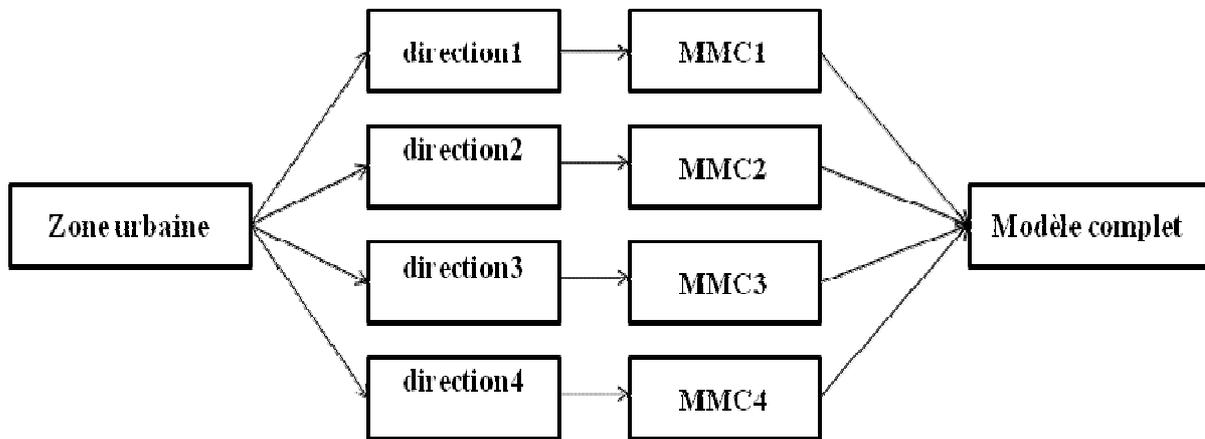


Figure 26. Suivi du masque urbain en 4 directions

Après avoir calculé les différents descripteurs dans toutes les dates qui sont toujours continus, ces vecteurs seront ensuite classés grâce à un classifieur non supervisé de façon à obtenir un espace d'observations discret. En même temps, on passe à la détection des relations spatiales et le suivi de leurs évolutions au cours du temps. Pour définir la structure la plus adéquate dans le cas des relations spatiales, nous pouvons prendre par exemple un seuil A égal à 10% et un seuil B égal à 90%. Dans ce cas, nous déclarerons que les deux objets *se touchent* si et seulement si la longueur de leur contour commun est inférieure à 10% de la longueur du contour de l'objet bleu *et* est inférieure à 10% de la longueur du contour de l'objet noir. Nous pourrions de même déclarer que l'objet bleu *recouvre* l'objet noir si et seulement si la longueur du contour commun est supérieure à 90% de la longueur du contour de l'objet bleu. Enfin, les deux objets *se chevauchent* dans tous les autres cas. Les seuils tels que décrits ici doivent être déterminés par expérimentation, afin de trouver quels seuils permettent d'obtenir l'interprétation la plus proche de celle d'un utilisateur. Nous visons à intégrer les relations spatiales comme un nouveau descripteur dans les modèles de Markov caché. Autrement dit, nous allons intégrer les informations obtenues dans notre modèle, afin de générer notre nouveau système. Le tableau 6 présente les résultats d'essais pour certaines images. Chaque image prise à deux instants distincts, nous présentons la relation spatiale détectée, les évolutions temporelles des relations spatiales, et les évolutions des intervalles basés sur l'algèbre des intervalles d'Allen. Pour calculer l'évolution des relations spatiales, nous utilisons l'indice de *EvSr* comme un indice pour les changements de calcul dans une relation spatiale entre deux instants  $t_i$  et  $t_{i+1}$ .

$EvSr =$  Temporal relation [spatial relationship ( $t_i$ ), spatial relationship ( $t_{i+1}$ )]

Par exemple:

If [spatial relationships ( $t_i$ ) = 'DISJOINT' and spatial

relationships ( $t_{i+1}$ ) = 'OVERLAP']

Then  $EvSr$  = 'Evolution forte'

Instants (i)	Relation (A, B)	EvSr	Modélisation des intervalles
[1998, 2000]	A disjoints B	Evolution faible	$i_1$ meets $i_2$
[2000, 2002]	A Meets B		
[2001, 2004]	A Meets B	Evolution nulle	$i_2$ overlap $i_3$
[2005, 2006]	A Overlaps B	Evolution forte	$i_3$ disjoint $i_4$
[2005, 2010]	A Covers B	Evolution moyenne	$i_4$ starts $i_5$

Tableau 6 : Résultats des relations spatio-temporelles

L'apprentissage numérique poursuit exactement le même objectif : il s'agit de faire en sorte, à l'aide d'une procédure numérique programmée et exécutée sur un ordinateur, d'inférer un modèle d'un processus que l'on observe et sur lequel on peut effectuer des mesures, c'est-à-dire un ensemble d'équations qui décrivent le processus observé et qui permettent de faire des prédictions concernant le comportement de celui-ci. A cette fin, on fait l'hypothèse que le processus peut être décrit avec la précision d'itération par une ou plusieurs fonctions qui contiennent des paramètres, et l'on ajuste ces derniers pour que cette ou ces fonctions s'ajustent aux données. L'apprentissage est un algorithme qui permet d'ajuster ces paramètres. Pour construire un MMCC, il est donc nécessaire de définir les états dans lequel le système peut être et ainsi que les observations possibles. Nous ne travaillons pas sur les données brutes du système que nous voulons modéliser, mais il faut faire une étape de conception qui vise à bien définir le type de modèle que nous voulons construire. Ensuite nous appliquons l'apprentissage suivant l'algorithme utilisé classiquement pour ce type de modèle.

Pour construire la base des variations entre les différentes dates pour les deux sources d'observations (voir figure 27), nous exploitons deux sources :

- Première source : Pour chaque image d'une série d'images multi-dates donnée nous commencerons par calculer les différents descripteurs (descripteurs de forme, descripteurs de texture) puis nous passerons à classifier les différents vecteurs caractéristiques et nous finirons par la détection des changements.

- Deuxième source : Nous allons associer à chaque image des descripteurs concernant la zone d'intérêt (pression démographique, PAU, SDA) et nous réitérons les mêmes traitements.

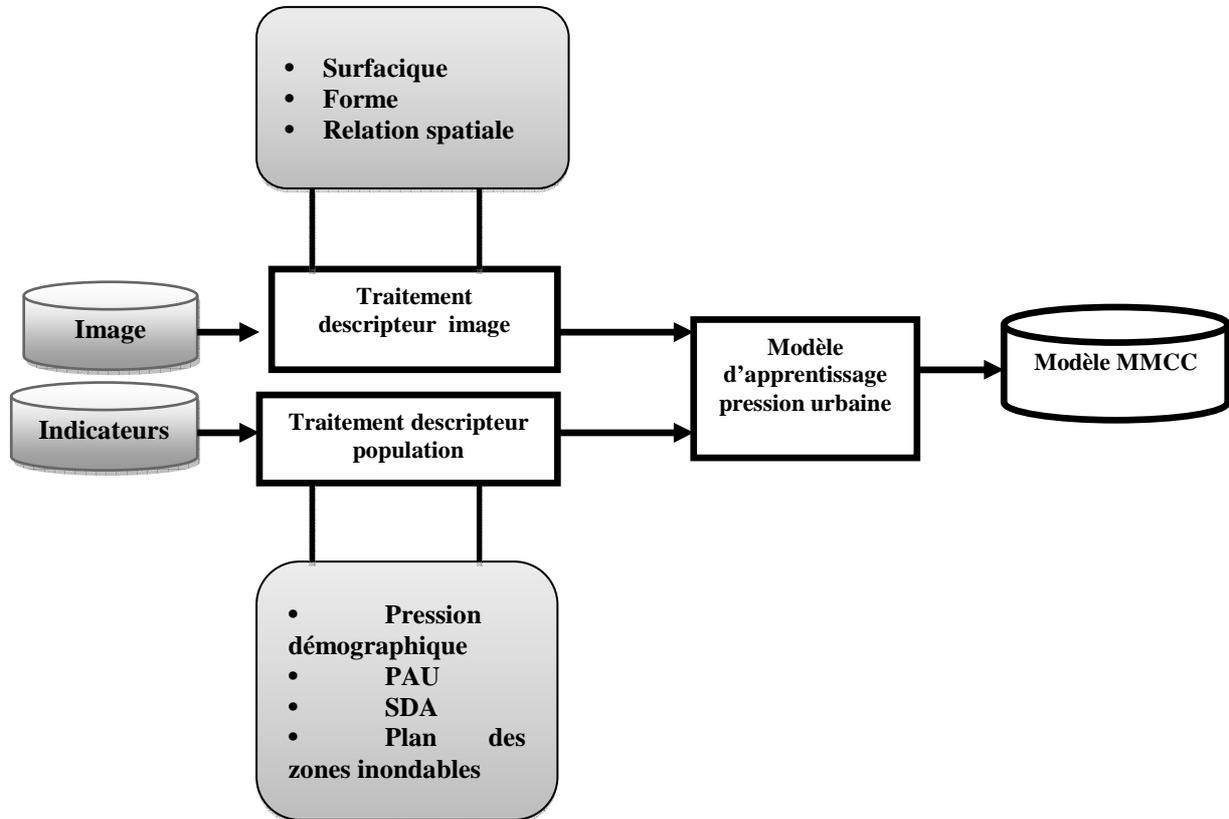


Figure 27: Construction de la base de variation dans un MMCC

Afin d'entraîner, un MMC à partir d'une structure connue, nous disposons pour cela d'une base d'apprentissage composé de séquences supposées représentatives des séquences que l'on souhaite modéliser (voir figure 28).

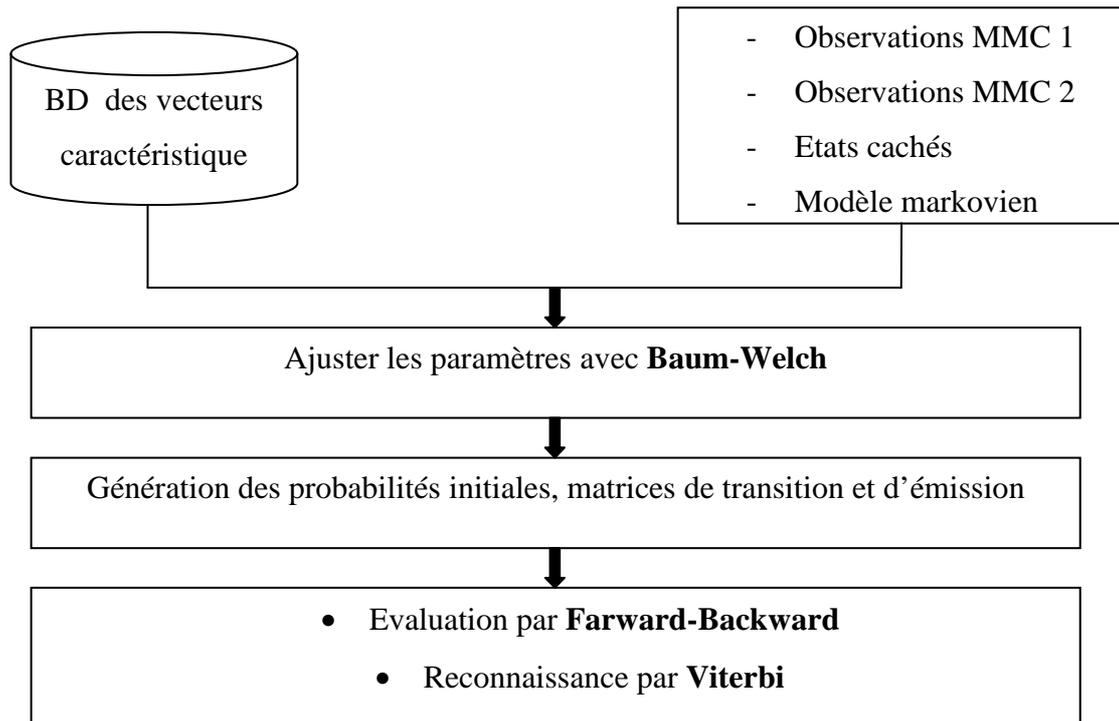


Figure 28 : Module d'apprentissage dans le cas du MMCC

## 5. Conclusion

Dans ce chapitre, nous avons présenté notre modélisation de détection et de prévision des changements dans les images satellitaires. Nous avons commencé par l'extraction des objets sujets de suivi, ainsi que leurs vecteurs caractéristiques. Ensuite, nous avons réduits ces vecteurs pour leur appliquer une classification. Enfin, nous avons utilisé un apprentissage supervisée et des techniques de détection et de prévision des changements dans deux cas différents qui sont la végétation et l'urbain. Dans le chapitre suivant, nous allons mettre en application notre méthodologie dans trois expérimentations.

## Expérimentations et résultats

### 1. Introduction

Dans le but de valider notre approche, nous avons développé trois expériences. La première consiste en une expérimentation générique, la deuxième est une application sur les forêts et la troisième concerne le suivi des zones urbaines.

### 2. Expérimentation générique [98]

Durant cette expérimentation, nous avons exploité des séries temporelles d'images satellites, en coopération avec les techniques d'extraction d'informations, pour l'analyse spatio-temporelle à base d'un modèle de Markov caché, la détection et la prévision des changements. Nous avons réalisé une analyse de performances sur plusieurs sites d'études en utilisant différentes séries temporelles d'images SPOT.

#### 2. 1. Source d'images

Nous allons expérimenter notre méthodologie sur un échantillon de quatre séquences de la série temporelle d'images satellitaires du projet ADAM [60] (voir figure 29). Chaque série est composée de 10 images acquises par SPOT 1,2 et 3. La résolution est de  $20 \times 20$ m. L'acquisition d'images a été mensuelle durant une période de 10 mois, allant d'octobre 2000 à juillet 2001. Ces séquences présentent quelques phénomènes qu'il est possible d'observer dans la STIS. La première série montre la récolte d'un champ, qui est l'activité humaine la plus observable du ciel. La seconde présente l'évolution de la forêt à l'automne. La troisième montre la maturation d'un champ de colza qui apparaît en blanc. Finalement, la quatrième série présente des récoltes et l'évolution d'une rivière.

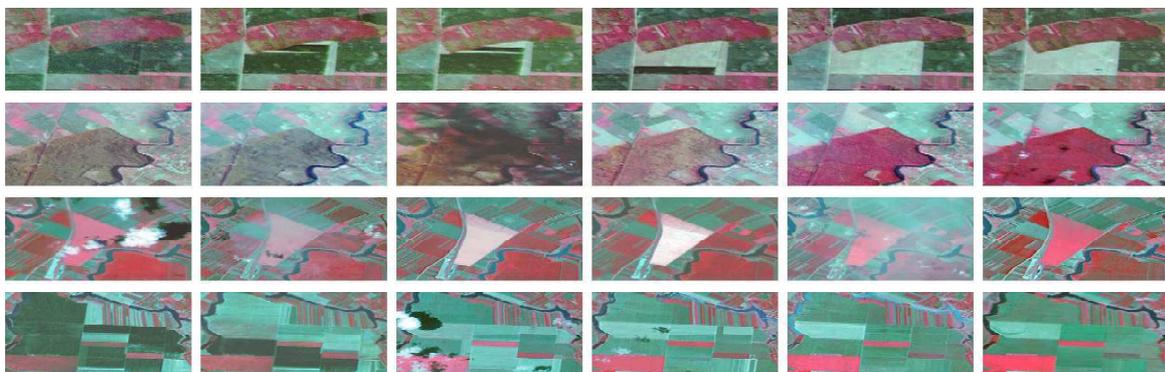


Figure 29. Quatre Séries temporelles d'images satellitaires du projet ADAM

## 2.2. Traitement et Apprentissage des observations

Dans cette section, nous allons commencer par analyser chaque image de la série temporelle et ce afin d'extraire les vecteurs caractéristiques de chaque région (voir tableau 7) et les enregistrer dans la base de données d'apprentissage.

Object	Area	Perimeter	Major Axis Length	Roundness	Feret Diameter	Compactness	Centroid	.....	Gray Centroid
R11 à T1	9668	440,66	164,2	0,63	110,95	0,68	-98,93	.....	-100,94
R11 à T2	11071	505,71	182,66	0,54	118,73	0,65	-97,103	.....	-99,104
.....	.....	.....	.....	.....	.....	.....	.....	.....	.....
R11 à T10	7449	464,63	144,42	0,43	97,39	0,67	-94,87	.....	-96,88

Tableau 7. Quelques vecteurs caractéristiques de la région R11 de la première séquence

Tous ces vecteurs ont été classifiés en employant les cartes SOM de Kohonen à l'aide du logiciel de fouille de données TANAGRA, par la suite chaque vecteur sera identifié par un code représentant sa classe. Finalement, notre système va essayer d'apprendre un MMC pour chaque série temporelle d'images satellites à partir de séquences d'observations, lorsque l'on fixe le nombre d'états cachés, c.à.d. un état pour chaque type d'événement spatio-temporel. La matrice de transition et la matrice d'émission et les probabilités de départ seront enregistrées dans la base de données d'apprentissage.

## 2.3. Interprétation des événements spatio-temporels

Dans cette partie notre guide méthodologique nous essayons d'interpréter les événements spatio-temporels de la région en question en se basant sur les MMC. Ces derniers trouvent leur intérêt dans la résolution de trois problèmes fondamentaux que sont l'évaluation, le décodage et l'apprentissage. Nous utilisons dans cette phase l'évaluation (prévision) et le décodage (reconnaissance). Étant données une CMC  $\lambda$  et une séquence  $o$  d'observations, nous cherchons à calculer la vraisemblance de cette séquence  $o$  avec la CMC  $\lambda$ , c'est-à-dire avec quelle probabilité la CMC  $\lambda$  engendre la séquence  $o$ . Cette valeur est notée  $P(O=o|\lambda)$ : cette probabilité est efficacement calculée par l'algorithme Forward ou par l'algorithme Backward. Pour cela nous avons conçu un outil dédié à l'évaluation pour calculer la probabilité d'une séquence particulière afin de prévoir les changements spatio-temporels. La reconnaissance consiste à trouver la séquence la plus probable d'état (caché) ayant conduit à la génération d'une séquence de sortie donnée qui se résout avec l'algorithme de Viterbi. Nous mesurons par la suite la précision de reconnaissance pour chaque région, qui est le pourcentage des événements reconnus à chaque instant  $t$  par rapport au nombre totale des

évènements de chaque région.

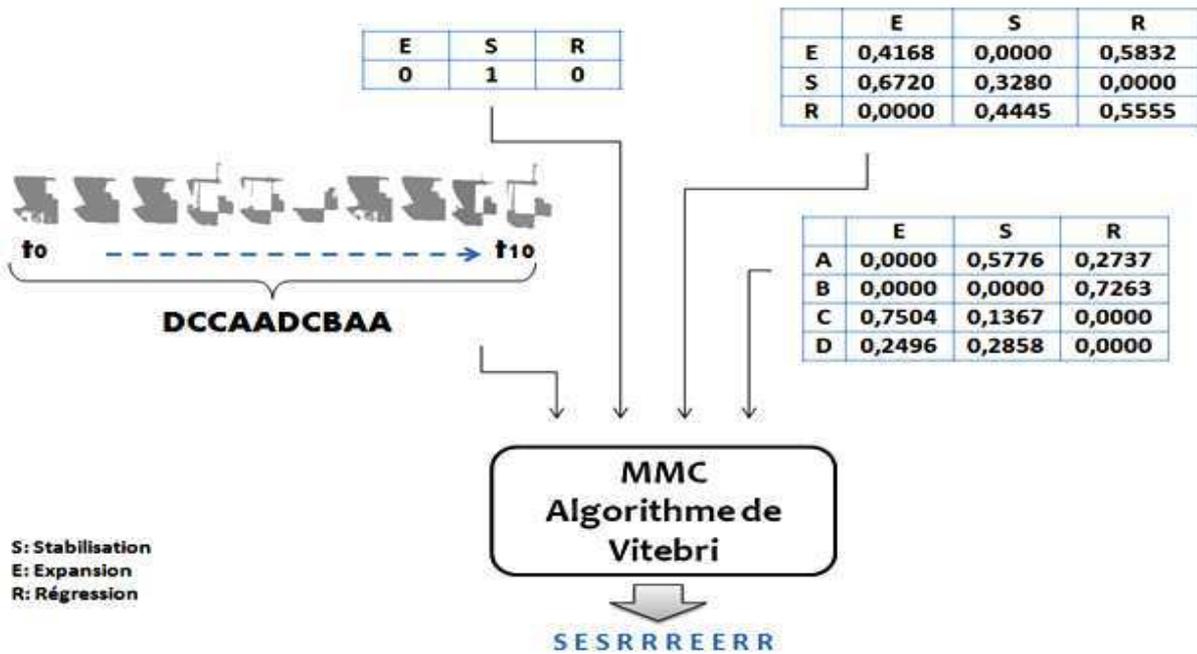


Figure 30. Exemple d'interprétation des évènements spatio-temporels.

La figure 30 montre un exemple d'analyse spatio-temporelle pour une région qui représente la récolte d'un champ, la reconnaissance de différents évènements (Stabilisation, Expansion et Régression) ayant conduit à la génération de la séquence de sortie donnée « DCCAADCBA A » se résout avec l'algorithme de Viterbi en se basant sur la base d'apprentissage précédemment construite contenant la matrice de transition et la matrice d'émission et les probabilités de départ. Cependant pour prévoir l'évènement le plus probable à une date futur, il suffit d'utiliser la fonction d'évaluation appartenant au système d'interprétation. Par exemple, nous voulons estimer l'évènement le plus probable à  $t_{11}$  et nous savons déjà la série d'évènements pour  $t_{10}$ , considérons la séquence d'observations « DACCCDABAA » ayant engendré la série d'évènements « SRREEERRSE »; nous devons commencer par le calcul des probabilités d'observation pour les séquences « DACCCDABAAA », « DACCCDABAAB », « DACCCDABAAC » et « DACCCDABAAD », par la suite nous distinguons la série d'observation la plus probable et par conséquent nous pouvons prévoir l'évènement de la date  $t_{11}$  à l'aide de la tâche de reconnaissance de notre sous système d'interprétation.

#### 2.4. Résultats expérimentaux

Nous présentons ci-dessous (Tableau 8) les résultats des essais expérimentaux. Pour chaque échelle de précisions d'interprétation des évènements spatio-temporels de longueur 10%, nous présentons le taux et nombres des régions correspondantes. Le tableau 9 montre des exemples d'analyse spatio-temporelle de quelques régions ainsi que leurs précisions de reconnaissance.

Précision d'interprétation des événements	Taux des régions	Nombre des régions
90% $\leq$ p $\leq$ 100%	15,625%	5
80% $\leq$ p $\leq$ 90%	28,125%	9
70% $\leq$ p $\leq$ 80%	31,25%	10
60% $\leq$ p $\leq$ 70%	9,375%	3
50% $\leq$ p $\leq$ 60%	6,25%	2
40% $\leq$ p $\leq$ 50%	6,25%	2
30% $\leq$ p $\leq$ 40%	3,125%	1
20% $\leq$ p $\leq$ 30%	0%	0
10% $\leq$ p $\leq$ 20%	0%	0
0% $\leq$ p $\leq$ 10%	0%	0
0%	0%	0
<b>Totaux</b>	<b>100%</b>	<b>32</b>

Tableau 8. Résultats expérimentaux de reconnaissance

Série temporelle	Type d'analyse	Exemple d'une région de la série	Événements interprétés	Précision
Série n°1	Observation de la récolte d'un champ	Région n°12	<i>S, E, R, R, R, E, E, R, R, R</i>	<b>100%</b>
Série n°2	Évolution de la forêt	Région n°23	<i>S, E, S, E, E, E, S, R, R, R</i>	<b>70%</b>
Série n°3	Maturation d'un champ de colza	Région n°34	<i>S, E, E, E, S, S, E, R, R, R</i>	<b>80%</b>
Série n°4	Évolution de la rivière	Région n°41	<i>S, S, S, S, S, R, R, R, R, E</i>	<b>90%</b>

Tableau 9. Exemples de résultats d'interprétation

Observation $O_{11}$ prévue	La séquence $S_{11}$ prévue	Logarithme de la probabilité de $S_{11}$	Probabilités de $E_{11}$	
<b>A</b>	BCCADDACBBA	-15.5448	Expansion	<b>0.0000</b>
			Stabilisation	<b>0.6281</b>
			Régression	<b>0.3719</b>
<b>B</b>	BCCADDACBBB	-15.5578	Expansion	<b>0.0000</b>
			Stabilisation	<b>0.0000</b>
			Régression	<b>1.0000</b>
<b>C</b>	BCCADDACBBC	<b>-17.4511</b>	Expansion	<b>0.0000</b>
			<b>Stabilisation</b>	<b>1.0000</b>
			Régression	<b>0.0000</b>
<b>D</b>	BCCADDACBBD	-16.7135	Expansion	<b>0.0000</b>
			Stabilisation	<b>1.0000</b>
			Régression	<b>0.0000</b>

Tableau 10. Exemple de résultats de prévision de la région R11.

Nous remarquons que l'emploi de la fonction d'évaluation de notre système nous permet de prévoir l'état de la région en question à  $t$ . Tenons cet exemple (voir tableau 10) ; la classe C est l'observation la plus probable à  $t_{11}$  de la région  $R_{11}$  dont le logarithme de la probabilité d'observer la séquence correspondante est «-17.4511», et par la suite nous pouvons estimer que l'état prévu de la région  $R_{11}$  à la date  $t_{11}$  sera « la Stabilisation ».

## 2.5. Expérimentation des données synthétiques

Nous avons réalisé la même expérimentation sur des données synthétiques afin de réduire le taux d'erreur par apport aux données brutes. En effet, les résultats des données synthétiques (voir tableau 11) nous ont permis d'évaluer les performances de notre système en comparant les décisions du système avec la vérité terrain. Ces données sont les événements spatio-temporels générés par les régions appartenant à la même classe, nous avons remarqué que ces données synthétiques sont identiques aux données élaborées (résultats interprétés). Nous avons obtenu un taux d'erreur compris entre 3,34% et 10% pour les données d'apprentissage, et entre 6,67% et 11,11% pour les données d'interprétation, ce qui nous a permis de dire que notre interprétation nous semble bonne.

	Séries synthétiques	Images multi dates	Classes des régions	Régions	Évènements Spatio-temporels	Taux d'erreur
Données d'apprentissage	Série I	6 Images	Classe 1	6 Régions	36 Évènements	<b>8,34%</b>
			Classe 2	6 Régions	36 Évènements	<b>5,55%</b>
			Classe 3	8 Régions	48 Évènements	<b>6,25%</b>
	Série II	6 Images	Classe 1	6 Régions	36 Évènements	<b>5,55%</b>
			Classe 2	5 Régions	30 Évènements	<b>10%</b>
			Classe 3	5 Régions	30 Évènements	<b>3,34%</b>
Données d'interprétation	Série III	6 Images	Classe 1	5 Régions	30 Évènements	<b>6,67%</b>
			Classe 2	4 Régions	24 Évènements	<b>12,25%</b>
			Classe 3	6 Régions	36 Évènements	<b>11,11%</b>

Tableau 11. Les résultats des données synthétiques.

Les résultats présentés sont issus d'une application implémentée en utilisant les moyens suivants :

- Environnement et langage de programmation : Matlab.
- Logiciels libres de traitement et d'analyse des images : MultiSpec 3.1, Image Analyzer 1.28, UTHSCSA ImageTool 3.00, TANAGRA

### 3. Expérimentation du cas des forêts [99]

Nous avons déjà définie les états cachés de cette application dans le chapitre précédent.

- **Habituel** : c'est l'état de la végétation lorsque sa surface est dans l'intervalle du 100% et 75% de la surface initiale.
- **Dégradé** : c'est l'état de la végétation lorsque sa surface devient dans l'intervalle du 75% et 50% de la surface initiale.
- **Critique** : c'est l'état de la végétation lorsque sa surface devient inférieure à 50% de la surface initiale.

Avec

- **Normale** : lorsque la variation est inférieure à 10% de la surface de la végétation à l'instant précédant et la surface de la végétation saine n'a pas diminué.
- **Alarmante** : lorsque cette variation est supérieure à 10% de la surface de la végétation à l'instant précédant ou la surface de la végétation saine a diminué.

**Remarque** : Les différents seuils pour passer d'un état à un autre (75% et 50%) et pour passer d'une instance à une autre (10%) sont choisis en collaboration avec un expert des forêts travaillant au sein du ministère de l'agriculture tunisien. Ainsi, la structure du modèle, les états cachés et les observations et les relations entre eux, sont définis. La prochaine étape aura pour but la détermination et l'ajustement des différents paramètres de ce modèle. Ces paramètres sont les probabilités de transition entre les états, les paramètres de la distribution de probabilité de génération et les probabilités initiales de visite. Cette partie présente une application ou une mise en œuvre de ce que nous avons vu dans les chapitres précédents. En d'autres termes, nous essayerons dans ce qui suit d'implémenter les algorithmes et les programmes qui permettront de réaliser les choix effectués lors de la phase de modélisation et d'atteindre ainsi les objectifs fixés dès le début.

#### 3.1. Environnement de développement

L'application est réalisée sous la plate forme MATLAB 7.1. Il sera nécessaire aussi de faire appel à certaines bibliothèques du BNT (Bayesian Network Toolbox), le toolbox réalisé et implémenté par Kevin Murphy et qui intègre la manipulation des Modèles de Markov Cachés.

### 3.2. Source d'images

Notre base d'images sera constituée de 15 séries temporelles d'images satellitaires décrivant chacune l'évolution d'une même scène sur une période de deux années aux environ et avec un pas variable allant de 1 à 6 mois entre deux acquisition successives. Les scènes proviennent de trois zones différentes de l'Afrique du nord, à savoir le nord de l'Algérie, le nord-est Tunisien et le nord-ouest de l'Égypte. Dix séries formeront les séquences d'apprentissage du modèle et les cinq restantes seront réservées pour les tests. La variabilité du pas pose un problème lors de la phase d'apprentissage puisqu'il faut définir des variations sur des périodes égales. Pour rester dans un cadre théorique juste, nous avons opté pour une interpolation bi-cubique qui nous permettra la régularisation du pas à une période égale à quatre (04) mois. Cette méthode trace parfaitement une surface bi-cubique à travers des points de données existants. La valeur d'un point interpolé est une combinaison des valeurs des seize points les plus proches.

**Remarque :** Toutes ces images ont été téléchargées à partir du site : [www.Glovis.usgs.gov](http://www.Glovis.usgs.gov).

Dans notre deuxième expérience, nous avons utilisé des images satellitaires multi-bandes issues du capteur Landsat TM (Paris.lan et Rio.lan). C'est Une série temporelle de dix images satellitaires prises à des dates différentes et décrivant une même zone. Ces images sont issues du capteur Landsat 7 bandes.

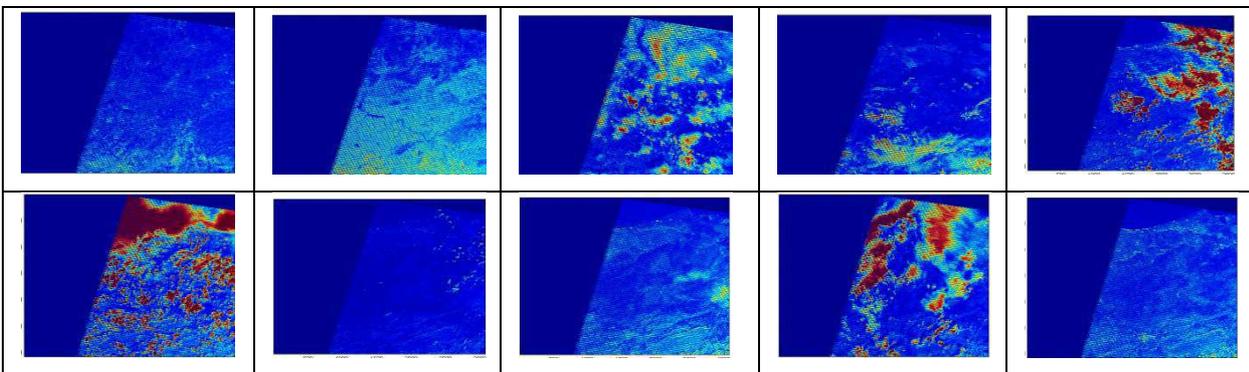


Figure 31. Extraction de la végétation en utilisant le NDVI

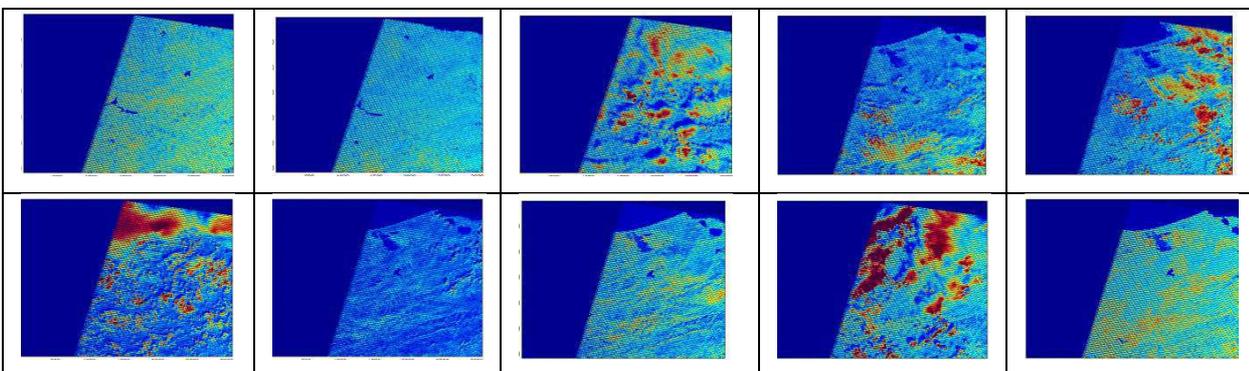


Figure 32. Extraction de la végétation en utilisant le RVI

Les descripteurs peuvent être calculés après extraction de la végétation (voir tableaux 31 et 32) en utilisant le NDVI et le RVI. Étant donné une image satellitaire multi-spectrale ou hyperspectrale, nous avons donc les valeurs de réflectance de chaque pixel de l'image à travers les différentes bandes. Ainsi, nous utiliserons les formules du NDVI et RVI pour le calcul de ces deux indices en chaque pixel de l'image. Une fois ces calculs réalisés, nous obtiendrons deux matrices correspondantes aux différentes valeurs de NDVI et RVI de l'image. Ensuite, nous passerons à l'extraction de la zone d'intérêt en utilisant la matrice des NDVI. Arrivé à ce stade, nous aurons besoin de fixer le seuil pour lequel les NDVI supérieurs seront considérés végétation. Habituellement, ce seuil doit être fixé par un expert du domaine, mais pour des raisons opératoires de réalisation nous choisirons ce seuil à 0.4 en s'inspirant de certains travaux dans la littérature. Nous avons laissé la possibilité de changer ce seuil à tout moment de la réalisation. Une fois ce seuil fixé, nous procédons au calcul d'un masque binaire (matrice) assignant la valeur 0 pour les pixels ayant un NDVI inférieur à 0.4 et la valeur 1 pour les pixels ayant un NDVI supérieur à 0.4. Ce masque servira à l'extraction de notre zone d'intérêt (pixels de valeur 1). Encore une fois, nous aurons besoin de fixer le seuil pour lequel les RVI supérieurs seront considérés comme végétation saine et dense. Habituellement, ce seuil doit être fixé par un expert du domaine, mais toujours pour des raisons opératoires de réalisation nous fixerons ce seuil d'une façon empirique et qui sera égal à la moyenne des RVI des pixels appartenant à la zone d'intérêt. De la même façon, nous calculerons un masque binaire assignant la valeur 0 pour les pixels ayant un RVI inférieur à la moyenne et la valeur 1 pour les pixels ayant un RVI supérieur à cette moyenne. Ce masque servira à différencier la végétation considérée comme étant saine et subissant peu de stress par rapport au reste de la végétation.

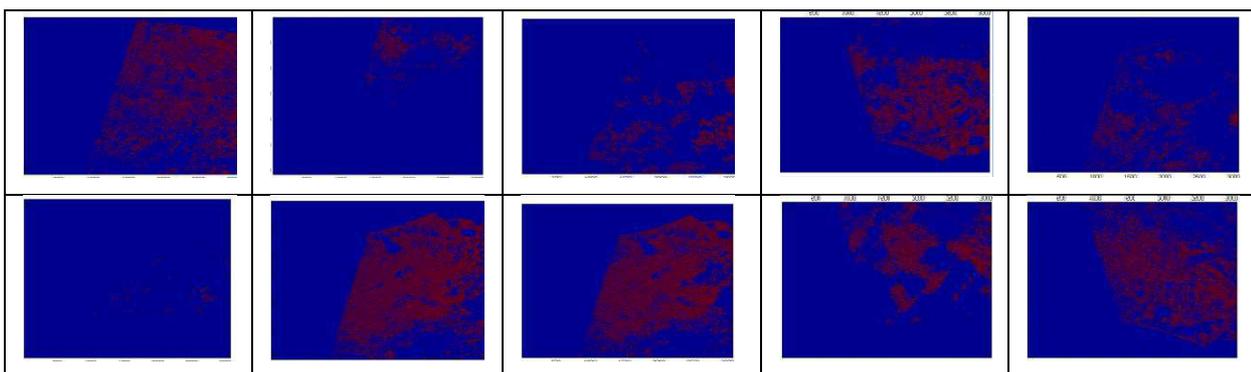


Figure 33. Extraction de la végétation saine

Ensuite nous calculons les vecteurs contenant les surfaces des végétations normales et des végétations saines (voir figure 33) (en pourcentage par rapport la surface totale : tableau 12) des zone extraites et correspondantes à la forêt.

surf	26,330	6,098	7,304	17,297	7,830	2,831	28,393	27,189	10,129	18,831
saine	22,7	4,42	5,21	10,58	4,25	1,012	21,39	18,45	8,67	11,35

Tableau 12. Calcul de la surface de la végétation normale et saine

A partir de ces vecteurs surfaces nous calculons les descripteurs correspondants à la forêt. Et qui sont respectivement, le descripteur de variation de la végétation, le descripteur du taux ou vitesse de cette variation et le descripteur de variation de la végétation saine (voir tableau 13).

Vv	100	23,131	27,742	65,693	29,737	10,751	100	95,759	35,674	66,322
Tvv	0	76,840	0	0	54,732	63,844	0	4,240	62,745	0
Vvs	0	-13,74	-1,14	-10,18	-6,84	-18,58	39,6	-7,47	17,72	-25,28

Tableau 13. Calcul de la vitesse de variation de la végétation normale et saine

### 3.3. Traitement et apprentissage des observations

La combinaison des trois descripteurs correspondants à un instant donné nous permettra de définir l'état « caché » de la forêt à cet instant en utilisant des règles d'appartenance. Les états observables sont les descripteurs précédemment calculés (voir tableau 14).

100	23,131	27,742	65,693	29,737	10,751	100	95,759	35,674	66,322
0	76,840	0	0	54,732	63,844	0	4,240	62,745	0
0	-13,74	-1,14	-10,18	-6,84	-18,58	39,6	-7,47	17,72	-25,28

1	6	6	4	6	6	1	2	6	4
HN	CA	CA	DA	CA	CA	HN	HA	CA	DA

Tableau 14. Définition des états cachés

L'algorithme d'apprentissage nécessite comme arguments les observations et les états cachés qui leur correspondent. Les calculs que nous venons de faire seront refaits pour d'autres séries temporelles d'images pour élargir la base d'apprentissage. Les résultats d'apprentissage sur une base de 10 séries sont les suivants :

- Les Probabilités de Première Visite des états:  $\pi$

HN	HA	DN	DA	CN	CA
0.267	0.13	0.2	0.067	0.2	0.13

- La matrice des probabilités de transition entre états:

	HN	HA	DN	DA	CN	CA
HN	0.538	0.115	0.102	0.089	0.025	0.128
HA	0.30	0.466	0	0.10	0	0.133
DN	0.562	0	0.187	0	0.062	0.187
DA	0.117	0.117	0.058	0.352	0	0.352
CN	0.071	0	0.071	0	0.428	0.428
CA	0.218	0.145	0.018	0.072	0.036	0.509

- Paramètres de la distribution de probabilité d'émission: B

Premier paramètre:  $\mu$  (Mu)

	HN	HA	DN	DA	CN	CA
98.57	98.57	95.83	62.13	60.81	30.51	22.33
0.12	0.12	2.73	3.14	20.08	0.059	29.52
4.54	4.54	-7.01	2.98	-4.36	10.86	-3.68

Deuxième paramètre:  $\sigma$  (Sigma)

HN			HA			DN		
14.9471	-0.8579	5.4041	63.009	-40.72	-18.229	56.7376	2.4699	-6.4498
-0.8579	0.4014	-0.4061	-40.72	35.647	12.09	2.4699	13.553	0.8979
5.4041	-0.406	84.829	-18.22	12.09	354.05	-6.4498	0.8979	4.2259
DA			CN			CA		
57.263	-58.349	-9.710	170.83	1.125	-73.259	172.489	-150.538	-9.433
-58.349	304.942	45.784	1.125	0.054	-0.593	-150.538	787.35	145.65
-9.710	45.781	140.691	-73.255	-0.593	54.84	-9.433	145.65	321.785

### 3.4. Interprétation des événements spatio-temporels

Une fois les paramètres manquants sont définis, nous pourrions utiliser le modèle pour déterminer le chemin correspondant à une observation donnée. Ceci nous permettra par la suite d'évaluer le degré de fidélité de notre modèle.

- Observation choisie pour le test du modèle:

Vv	100	100	100	100	65.2	39.1	25.8	16.6	13.1	17.2	27.6	41.2	54.7	65.1	69.3
Tvv	0	0	0	0	33.2	41.5	33.6	35.8	21.1	0	0	0	0	0	0
Vvs	0	-62.4	14.3	0.3	-5.1	-36.5	5.5	11.1	11.9	6.1	3.2	1.1	0.3	0.1	0.01

- Chemin associé à cette observation et déterminé par le modèle.

1	1	1	1	4	4	6	6	6	5	5	5	4	3	3
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Déterminons le chemin correspondant à la même observation en se basant sur les règles définies précédemment.

1	2	1	1	4	6	6	6	6	5	5	5	5	3	3
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Le taux d'erreur pour cette observation est égal à 20%.

Cette erreur étant recalculée pour dix observations différentes, nous obtenons une erreur moyenne de : 16,78 %. Nous remarquons qu'à chaque fois l'erreur survient à un endroit différent.

#### 4. Expérimentation du cas de l'urbain

L'objectif principal de cette troisième expérience est l'extraction et le suivi du masque urbain par un modèle de Markov caché couplé. En d'autres termes, ayant une série d'images multi-dates représentant une même zone d'intérêt, en particulier une zone urbaine, nous cherchons à modéliser les variations entre ces images par un modèle adéquat, interpréter et analyser ces variations pour pouvoir prédire les changements futures de cette zone. La réalisation de cet objectif passe par une chaîne de traitements et exige une intégration à tous les niveaux : prétraitement, segmentation, détection des changements et modélisations des variations.

Nous avons en entrée une séquence d'images, qui décrit une zone géographique à partir d'images acquises à des dates différentes. Le sous système de traitement va permettre de la rendre interprétable. Ce traitement comporte, une phase d'extraction de la zone urbaine, et une phase d'extraction de données caractéristiques calculées à partir de différents types de descripteurs. Par la suite, le sous système d'apprentissage trouve dans cet espace le MMCC le plus adapté à ce que nous cherchons à apprendre. Finalement, nous pouvons utiliser le modèle pour prédire des événements futurs.

##### 4.1. Extraction du masque urbain [100]

Pour valider notre méthodologie, nous avons utilisé une série d'images SPOT du grand Tunis qui sont constituées de deux régions. Dans notre cas, nous allons identifier les différentes relations entre

les deux classes (bâtiments et routes). Dans une étude préliminaire, nous utilisons deux images SPOT contenant des différents tissus urbains. La figure 34 montre les images SPOT de la région de grand Tunis, utilisées.

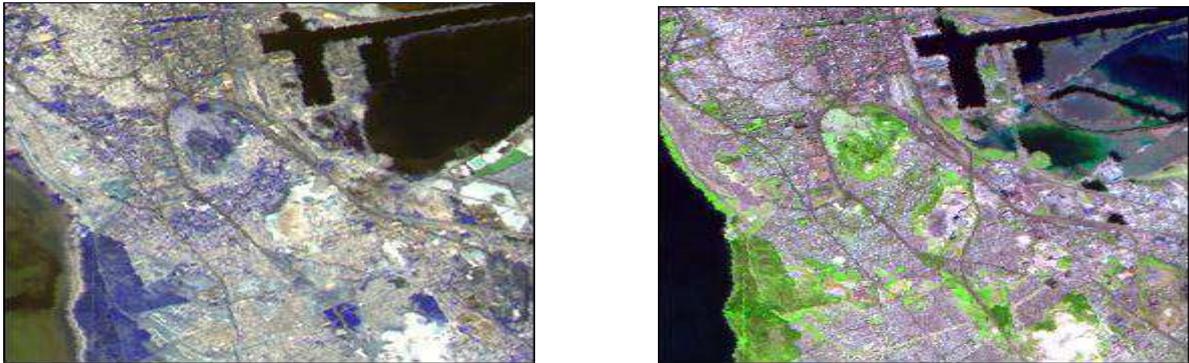


Figure 34. Images SPOT de Grand Tunis en 1987 et 2001

Et puisque cette série d'image n'est pas suffisante pour tourner les chaînes de Markov cachés, nous avons utilisés une série d'images synthétiques de 102 images, qui contient deux objets de différentes couleurs. Les résultats obtenus seront montrés dans les parties suivantes. Pour extraire le masque urbain nous avons utilisé la texture, afin de détecter les zones urbaines. La figure ci-après montre le masque urbain extrait à partir d'une image SPOT, ainsi le masque monochrome, et enfin la zone urbaine propre.

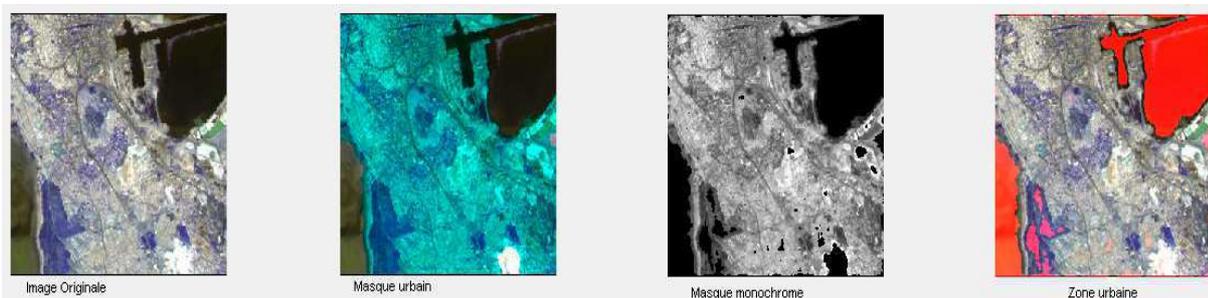


Figure 35. Extraction du masque urbain

La figure 35 présente un masque urbain extrait à partir d'une image SPOT, ainsi ce masque a été convertit en noir et blanc afin de montrer un masque claire qui désigne la zone urbaine détectée de cette image.

#### 4.2. Segmentation et classification du masque urbain

Une fois que le masque urbain obtenu, une phase de segmentation et classification sera effectuée, afin de détecter les différentes relations spatiales entre ces différents tissus urbains.

Pour segmenter et identifier les routes et les bâtiments à partir du masque urbain extrait nous avons utilisé l'algorithme de croissance des régions, qui à pour objectif de grossir une région étudiée selon les pixels voisins à travers l'homogénéité et l'étude de mesure de similarité.

La figure 36 montre les deux étapes de segmentation et de classification réalisée au niveau du masque urbain ainsi les différentes distances euclidiennes obtenues entre les différents tissus urbains.

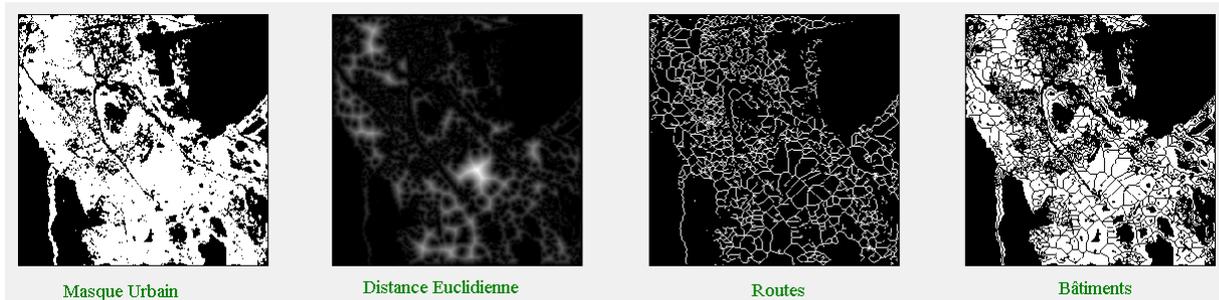


Figure 36. Segmentation et classification du masque urbain

Dans ce cas, nous pouvons modéliser l'expansion des régions en fonction de l'évolution des relations spatiales. Pour les descripteurs de texture nous avons utilisé 23 indices d'Haralick [101] comme l'indiqué dans la figure 37, prenons l'exemple de l'indice d'homogénéité (homom) qui va décrire la variation à l'intérieur du masque qui va nous aider à détecter les changements intra-urbains.

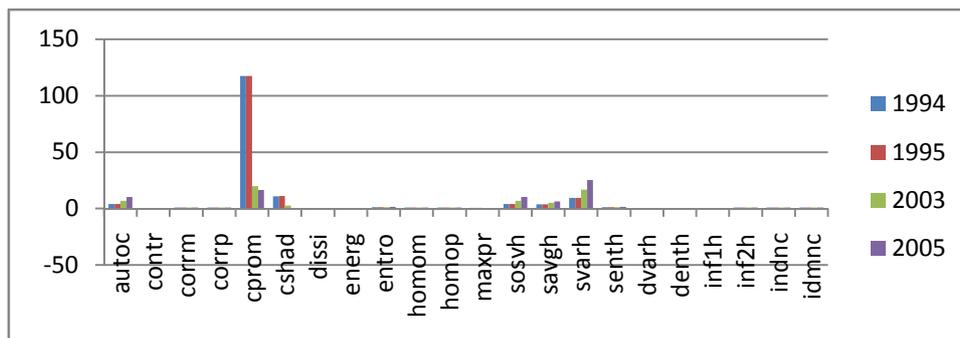


Figure 37. Variations d'indices d'Haralick

Tous ces vecteurs ont été classifiés en employant les cartes SOM de Kohonen à l'aide du logiciel de fouille de données Tanagra, par la suite chaque vecteur sera identifié par un code représentant sa classe. La série d'images utilisée dans la section précédente, est insuffisante pour estimer des paramètres, car elle nécessite plusieurs observations, alors que pour la modélisation nous allons présenter un autre exemple, qui permet de modéliser la pression urbaine en fonction de l'évolution urbaine (EvolUrb) et l'évolution de la population (EvolPop). Les données de l'exemple sont fournies par l'Agence Européenne de l'Environnement [102]. Nous aurons la tâche de définir la structure la plus adéquate qui nous permettra l'analyse et le suivi de ce phénomène. Il est donc nécessaire de définir quels sont les états dans lesquels le système peut être, les différentes valeurs que peut prendre la variable "état" et quelles sont les observations possibles. Pour cela, il faudra faire une étape de conception qui vise à bien définir le type de modèle que nous voulons construire.

### 4.3. Résultats expérimentaux [103]

On propose le modèle MMCC suivant :

- Observations MMC 1: {'A : Expansion faible', 'B : Expansion forte', 'C : Expansion très forte'}
- Observations MMC 2: {'D : Pression démographiques faible', 'E : Pression démographique moyenne', 'F : Pression démographique forte'}
- Etats : {'1: Pression faible', '2: Pression moyenne', '3: Pression forte', '4: Pression très forte'}

Pour calculer les observations nous allons utiliser EvolUrb comme un indice pour calculer les changements d'une zone urbaine entre deux dates t+1 et t :

$$\text{EvolUrb}(t-1, t) = ((\text{Surface de la zone urbaine en } t) - (\text{Surface de la zone urbaine en } t-1)) / (100 * (\text{Surface de la zone urbaine en } t-1))$$

Puis nous allons classer cet indice selon des règles :

- **Règle 1** : Si  $\text{EvolUrb} < 10\%$  Alors masque en expansion faible.
- **Règle 2** : Si  $10\% < \text{EvolUrb} < 30\%$  Alors masque en expansion moyenne.
- **Règle 3** : Si  $\text{EvolUrb} > 30\%$  Alors masque en expansion forte.

L'exemple permet de modéliser la pression urbaine en fonction de l'expansion urbaine et la pression démographique. C'est la raison pour laquelle nous allons utiliser un autre indice : EvolPop qui permet de mesurer la pression démographique entre deux dates t+1 et t.

$$\text{EvolPop}(t-1, t) = (\text{Population } t) - (\text{Population } t-1) / (100 * (\text{Population } t-1))$$

Nous appliquons les règles suivantes :

- **Règle 1** : Si  $\text{EvolPop} \geq 10\%$  Alors pression démographique forte
- **Règle 2** : Si  $3\% < \text{EvolPop} < 10\%$  Alors pression démographique moyenne
- **Règle 3** : Si  $\text{EvolPop} < 3\%$  Alors pression démographique faible

Après la détermination de 'EvolUrb' et 'EvolPop', Les deux pressions sont combinées pour déterminer l'état caché du modèle selon ces règles :

- **Règle 1** : SI  $\text{EvolUrb} < 10\%$  ET SI  $\text{EvolPop} < 3\%$  Alors Etat caché =1
- **Règle 2** : SI  $\text{EvolUrb} < 10\%$  ET SI  $3\% < \text{EvolPop} < 10\%$  Alors Etat caché =2
- **Règle 3** : SI  $\text{EvolUrb} < 10\%$  ET SI  $\text{EvolPop} > 10\%$  Alors Etat caché =3
- **Règle 4** : SI  $10\% < \text{EvolUrb} < 30\%$  ET SI  $\text{EvolPop} < 3\%$  Alors Etat caché =2
- **Règle 5** : SI  $10\% < \text{EvolUrb} < 30\%$  ET SI  $3\% < \text{EvolPop} < 10\%$  Alors Etat caché =3
- **Règle 6** : SI  $10\% < \text{EvolUrb} < 30\%$  ET SI  $\text{EvolPop} > 10\%$  Alors Etat caché =3
- **Règle 7** : SI  $\text{EvolUrb} > 30\%$  ET SI  $\text{EvolPop} < 3\%$  Alors Etat caché =3
- **Règle 8** : SI  $\text{EvolUrb} > 30\%$  ET SI  $3\% < \text{EvolPop} < 10\%$  Alors Etat caché =3

- **Règle 9 : SI EvolUrb > 30% ET SI EvolPop > 10% Alors Etat caché = 4**

Voici un exemple de couplage de deux descripteurs (voir tableau 15):

EvolUrb	A	B	A	C	B	A	B	C
EvolPop	E	F	D	D	F	E	E	F

⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
▼	▼	▼	▼	▼	▼	▼	▼	▼

Couplage	2	3	1	3	3	2	3	4
----------	---	---	---	---	---	---	---	---

Tableau 15 : Exemple de couplage de descripteurs

Les résultats de l'apprentissage sont les suivant :

	1	2	3	4
1	3,8119E-07	2,6731E-14	0,99921719	0,00078243
2	0,1838668	7,3439E-21	0,05051254	0,76562066
3	6,3579E-05	0,40926456	8,21E-18	0,59067186
4	0,23942219	0,15072182	0,60985598	5,0901E-21

	1	2	3	4
A	0,12094617	0,05006884	0,90508103	0,0027496
B	0,8307884	0,94993116	1,4308E-07	1,4499E-10
C	0,04826543	3,0441E-10	0,09491883	0,9972504

**La matrice de transition**

**La matrice d'émission**

	1	2	3	4
	0,49917586	7,5284E-11	0,24006433	0,26075981

**Les probabilités initiales**

Avec l'algorithme de Viterbi, et en se basant sur la base d'apprentissage précédemment construite contenant la matrice de transition et la matrice d'émission et les probabilités de départ, Nous pouvons exploiter le pouvoir de prédiction des modèles Markoviens en général, et spécialement celui de notre modèle. Pour prévoir l'évènement le plus probable à une date futur, il suffit d'utiliser la fonction d'évaluation appartenant au système d'interprétation. Remarquons que l'emploi de la fonction d'évaluation de notre système nous permet de prévoir l'état de la région en question à t. Elle fournit une bonne prédiction des changements spatio-temporels conjointement avec un taux d'erreur égale à 20%.

## 5. Conclusion

Nous avons présenté dans ce chapitre les différents aspects du développement de notre approche méthodologique. Nous avons décrit aussi l'étude expérimentale que nous avons menée pour évaluer la performance de notre méthodologie. Les comparaisons des décisions avec la vérité terrain ont

montré une précision relativement acceptable. En effet, 75% des évènements ont été reconnus à, au moins, une précision de 70% ; et 15,625% des évènements ont été interprétés à une précision de 100%. C'est pour quoi la méthodologie présentée dans cette thèse est prometteuse. Elle fournit une bonne prédiction des changements spatio-temporels conjointement avec le suivi de ces derniers. En outre, elle est transférable à des applications multiples.

## Conclusion générale et perspectives

Dans le cadre de cette thèse, nous avons étudié la résolution, par processus stochastiques, les problèmes de modélisation, de détection et de prévision des changements. Nous avons axé notre travail sur la modélisation et l'estimation d'une classe particulière de l'occupation du sol représentant un objet donné. L'objectif principal était la modélisation spatio-temporelle à base de modèles stochastiques pour le suivi d'objets en imagerie satellitaire. L'originalité principale de notre étude porte sur deux points principaux:

- L'utilisation des modèles de Markov cachés pour la modélisation et la prévision des changements. Ce modèle est couramment utilisé pour la résolution de problèmes de segmentation d'image, car la variable cachée peut représenter une classification, considérée alors comme solution du problème de segmentation. En revanche, dans le cas des problèmes de prévision, plus complexes, où les données ne sont pas nécessairement des images, l'utilisation de ce modèle est, à notre connaissance, originale.
- Nous avons considéré le modèle de Markov caché comme une régularisation du problème et non plus comme solution. Nous avons choisi, pour tous les problèmes traités, de calculer l'estimateur de la moyenne a posteriori par un algorithme d'échantillonnage de Baum Welch, méthode qui nous semble particulièrement adaptée à l'utilisation des modèles de Markov cachés et applicable dans le cas de problèmes de prévision. Nous avons appliqué l'approche proposée sur divers données satellitaires et dans divers conditions. Ceci nous permet de montrer la généralité de notre approche en particulier ceux de prévision. La difficulté majeure restant l'échantillonnage d'une loi de probabilité non nécessairement gaussienne et dépendant du caractère non linéaire du problème.

Dans cette thèse, nous avons proposé une nouvelle méthodologie générique, pour pallier aux insuffisances des méthodes habituelles de détection et de prévision. Cette méthodologie permet de suivre et prévoir conjointement les nombreux événements spatio-temporels en tenant compte de plusieurs sources d'information. Pour accomplir cet objectif, nous avons été placés dans le cadre de deux domaines ; l'extraction d'information à partir des données brutes, et l'analyse stochastique avec les modèles markoviens. Nous avons commencé par la préparation de la base d'images. Puis, l'extraction des zones d'intérêt, moyennant une technique adéquate. Par la suite, les images de chaque série sont comparées dans l'ordre chronologique de leurs acquisitions pour détecter les changements que subit la zone d'intérêt d'un instant d'acquisition au suivant. Ensuite, ces changements sont modélisés par un modèle de Markov caché (discret ou continu, simple ou couple). Les séquences d'images sont utilisées pour l'entraînement et l'apprentissage de ce modèle afin de définir ses paramètres manquants. Une fois le modèle est complet, nous le ferons subir une phase d'évaluation pour examiner sa robustesse et sa fidélité. Enfin le modèle est utilisé pour la prédiction des variations futures de toute zone similaire aux zones d'apprentissage du modèle. Nous avons

réalisé une plate forme pour l'extraction d'une région (forêt et urbaine) dans une image satellitaire, la détection des changements à travers une série temporelle d'images et l'apprentissage d'un MMC pour la prévision de l'état futur de cette région. L'évaluation du modèle a fournit des résultats satisfaisantes avec un taux d'erreur acceptable.

### **Perspectives**

Ce travail n'est qu'une première tentative pour la résolution des problèmes de prévision avec une modélisation par champ de Markov caché. Il ouvre donc de nombreuses perspectives, à la fois sur l'aspect méthodologique de l'approche proposée et sur l'application en télédétection. Vers le non supervisé : Les méthodes que nous avons proposées dans cette étude sont partiellement supervisées. Les résultats obtenus nous ont encouragés à envisager les perspectives suivantes :

L'enrichissement de la base d'échantillon par de nouvelles images représentant d'autres zones d'étude. Cela donnera plus de généralité au système et les résultats seront plus généraux et par suite les prédictions le seront aussi.

L'application du modèle sur d'autres domaines d'application tout en tenant compte des spécificités et des caractéristiques de ce domaine. En termes d'exemple, nous pourrions suivre les changements et les variations que subissent les zones intra-urbaines, la gestion des risques, la météorologie, le suivi des opérations culturelles, etc.

L'intégration d'autres descripteurs pour le suivi des variations. Puisque ses variations dépendent et interagissent nécessairement avec l'espace entourant la zone d'étude.

L'intégration des techniques de détection du changement dans notre sous système d'apprentissage et d'évaluer l'effet de cette amélioration sur la performance de ce système.

L'exploitation d'autres modèles markoviens tels que les MMC couples, les MMC couplés, et les MMC triplets et ce afin de gérer plusieurs sources d'observations.

# Bibliographie

- [1] Thomas Lillesand T., Kiefer R. W. et Chipman J., *Remote Sensing and Image Interpretation*, 6th Edition (University of Wisconsin, Madison) August 2008.
- [2] <http://eoedu.belspo.be/fr/guide/indices.asp?section=3.9>
- [3] Shepherd J.D. et Dymond J.R., , *Correcting satellite imagery for the variance of reflectance and illumination with topography*, 13 pages, International Journal of Remote sensing, Vol.24, Issue.17. 2003.
- [4] Baiocchi Valerio, Dominici Donatella et Del Guzo Filippo, *Utilisation des images satellites à haute résolution pour la surveillance d'une zone côtière*, 7 pages, Géomatique Expert n°51 Juin-Juillet. 2006.
- [5] Anthony R. Palmera et Andre F. van Rooyenb, *Detecting vegetation change in the southern Kalahari using Landsat TM data*, Journal of Arid Environments, Pages 143-153, 1997.
- [6] Duda R. O., Hart P. E., David G. et Stork D. G., *Pattern Classification*, Second Edition Wiley-Interscience, 2001.
- [7] Kouani A., El Jamali S., et Talbi M., *Analyse en composantes principales. Une méthode factorielle pour traiter les données didactiques* Radisma, n° 2, 2007.
- [8] Rakotoniaina S., Collet C. et Ratsimbazafy JB, *Fusion d'image de télédétection à l'aide de l'analyse ondelettes multirésolution pair*, Dans "La télédétection en francophonie: analyse critique et perspective", Ag. univ. de la Francophonie: pp. 85-94. 1999.
- [9] <http://www.chambreuil.com/public/education/3.2/stat/projet/applications.html>.
- [10] Ho P. *Image segmentation*, Edited by Pei-Gee Peter Ho, Intech, 2011.
- [11] Pratt W. K., *Digital Image Processing*, John Wiley & Sons, inc., Third Edition, 2001
- [12] Horowitz S.L. et Pavlidis T., *Picture segmentation by a directed split and merge procedure*, CMetImAly77, 1977.
- [13] Giraudon D., *A computational approach for corner and vertex detection*, International Journal of Computer Vision 1993.
- [14] Guindon B., *Computer-Based Aerial Image Understanding: A Review and Assessment of its Application to Planimetric Information Extraction from Very High Resolution Satellite Images*, Canadian Journal of Remote Sensing, vol. 23, 1997.
- [15] Hornsby K. et Egenhofer M. J., *Identity-based change: a foundation for spatio-temporal knowledge representation*, International journal of geographical information science, Vol.14, No.3, 207-224. 2000.
- [16] Langran G., *Time in Geographic Information Systems* London: Taylor and Francis. 1992.
- [17] Pantazis D., *La méthode de conception des SIG : MECOSIG et CONGOO*, thèse de doctorat en Faculté des Sciences, Université de Liège. 1994.
- [18] Cheylan J.-P. et Lardon S. *Toward a conceptual model for the analysis of spatio-temporal processes* In FRANK A., CAMPARI L., eds, Spatial Information Theory. COSIT'9

- Conference. Berlin: Springer Verlag, Lecture Notes in Computer Science n° 716, 478 p. ISBN: 3-5405-7207-4. 1993.
- [19] Thériault M. et Claramunt C., *La représentation du temps dans les SIG: une nécessité pour la recherche interdisciplinaire*, Revue internationale de Géomatique, vol. 9, n° 1, pp. 67-99. 1999.
- [20] Galton A., *Toward a Qualitative Theory of Movement* In FRANK A.U., KUHN W., eds, Spatial Information Theory: A Theoretical Basis for GIS. Proceedings of the International Conference. Berlin and Heidelberg: Springer-Verlag, pp. 1-15. ISBN: 3-5406-0392-1. 1995.
- [21] Vieu L., *Spatial representation and reasoning in artificial intelligence*. In O. Stock, éditeur, Spatial and Temporal Reasoning, pp. 5-41, Dordrecht, Kluwer, 1997.
- [22] Egenhofer M., *A formal definition of Binary Topological Relationships*. In Litwin, W. & Schek, H. (Eds.) Third International Conference on Foundations of Data Organization and Algorithms (FODO). Paris, France, Springer-Verlag 1989.
- [23] Frank A. U., *Qualitative spatial reasoning about distances and directions in geographic space* Journal of Visual Languages & Computing, vol. 3, pp. 343-371, 1992.
- [24] El-Kwae, E. A., et Abuka K., M. R. *A robust framework for content-based retrieval by spatial similarity in image data bases*. ACM Transactions on Information Systems (TOIS) 17, 2, 174 –198. April 1999.
- [25] Egenhofer M, J. et Sharma D.M., *A critical comparison of the 4-intersection and 9-intersection models for spatial relations: Formal analysis*, Journal Geoinformatica, vol 4(4), 1993.
- [26] Egenhofer, M. J., Davidand M., et Mark J.H., *The 9-intersection : Formalism and its uses for natural-language spatial predicates* Tech. Rep. 94-1. 1994.
- [27] Schneider M., et Behr T., *Topological relationships between complex spatial objects*. ACM Transactions on Database Systems, vol. 31(1), pp. 39-81. 2006.
- [28] Kim B., et Um K., *2d+ string: A spatial meta data to reason topological and directional relationships* In Proceedings of the 11th International Conference on Scientific and Statistical Database Management IEEE Computer Society, pp. 112. July 1999.
- [29] Walker A.R., Pham B., et Moody M., *Spatial bayesian learning algorithms for geographic information retrieval*. In GIS '05: Proceedings of the 13<sup>th</sup> annual ACM international workshop on Geographic information systems (NewYork, NY, USA, 2005), ACM Press, pp. 1 05 –1 14. 2005.
- [30] Lee J., Oh J., et Hwang S., *Strg -index: spatio -temporal region graph indexing for large video databases*. In SIGMOD '05: Proceedings of the 2005 ACM SIGMOD international conference on Management of data (New York, NY, USA, 20 05), ACM Press, pp. 718–729. 2005.
- [31] Allen J. F., *An interval-based representation of temporal knowledge*. In Proceedings of the 7<sup>th</sup> International Joint Conference on Artificial Intelligence (IJCAI'81),pp. 221-226, 1981.
- [32] Allen J. F., *Maintaining Knowledge about Temporal Inetrvals* Communications of the ACM, vol. 26(11) pp. 832-843. 1983.
- [33] Vilain M., et Kautz H., *Constraint propagation algorithms for temporal reasoning*. In AAAI-86 Proceedings, pp. 377-382. 1986.

- [34] Wolter F., et Zakhryashev M., *Spatio-temporal representation and reasoning based on RCC-8*, Seventh Conference on Principles of Knowledge Representation and Reasoning KR, Breckenridge, USA, Morgan Kaufmann, 2000.
- [35] Muller P., *Topological Spatio-Temporal Reasoning and Representation*. Computational Intelligence, vol. 18, pp. 420-450. 2002.
- [36] Muller P., *Éléments d'une théorie du mouvement pour la formalisation du raisonnement spatio-temporel de sens commun*. Institut de recherche en informatique de Toulouse. Toulouse, Université Paul Sabatier, 1998.
- [37] Ren W., Singh S., et Zhu Y.S., *State-of-the-art on spatio-temporal information-based video retrieval*, *Pattern Recognition* vol. 4 (2), pp. 267 – 282. 2009.
- [38] Bittner T., *Qualitative spatio-temporal relations*, Qualitative Reasoning Group, Department of Computer Science, Northwestern University, pp. 1-13. 2008.
- [39] Claramunt C., et Jiang B., *An integrated representation of spatial and temporal relationships between evolving regions*, *J Geograph Syst*, vol. 3, pp. 411–428. 2001.
- [40] Inekej J.M., Vander Hama A., Jan W., Strien V., Oleksiak A., Richard J.A., Wezel V., et Postma A., *Temporal characteristics of working memory for spatial relations: An ERP study*, *International Journal of Psychophysiology*, vol. 77, pp. 83 – 94. 2010.
- [41] Salamat N., et Zahzah E.H., *Fuzzy spatio-temporal relations analysis*, 7th International Conference on Information Technology : New Generations ITNG 2010, Las Vegas, Nevada : United States. 2010.
- [42] Goldewijk K.K., *Estimating global land use change over the past 300 years : The hide database Glob Biogeochem Cycles*, Vol. 15, n°2, pp. 417-434. 2001.
- [43] Singh, A., *Digital change detection techniques using remotely-sensed data*. International Journal of Remote Sensing, vol. 10, pp. 989-1003. 1989.
- [44] Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., *Digital change detection methods in ecosystem monitoring: a review*. International Journal of Remote Sensing, vol. 25, pp. 1565-1596. 2004.
- [45] Macleod R.B. et Congalton R.G., *A quantitative comparison of change detection algorithms for monitoring eelgrass from remote sensed data*. Photogrammetric Engineering and remote sensing, vol. 64, pp. 207-216. 1998.
- [46] Smith A.J., Wright R.K., Jantz C. et Tringe J.. *Application of multitemporal Landsat data to map and monitor land cover and land use change in the chesapeake bay watershed*. Mutitemp03. Ispra, Italy, in press. 2003.
- [47] Dompierre J., *La méthode de Gram-Schmidt Algèbre linéaire I* — MATH 1057 F, Département de mathématiques et d'informatique Université Laurentienne, 2011.
- [48] Pham et al., *Démarche méthodologique pour la détection des changements d'un milieu morcelé en utilisant des images à moyenne résolution spatiale : application à une région littorale au Viêt-nam*. *Téledétection*, vol. 7(5) p. 302-323. 2007.
- [49] Lyon, J. G., Yuan, D., Lunetta, R. S., et Elvidge, C. D., *A change detection experiment using vegetation indices*. Photogrammetric Engineering and Remote Sensing, vol. 64, pp. 143–150. 1998.

- [50] Lu D., Mausel P., Brondi'Zio E. et Moran E., *Change detection techniques*, International Journal of Remote Sensing, vol. 25, No. 12, pp. 2365–2407, 20 June, 2004.
- [51] Guérin C., Binet R. et Pierrot-Deseilligny M., *Détection des changements d'élévation d'une scène par imagerie satellite stéréoscopique*, publié dans « RFIA 2012 », Reconnaissance des Formes et Intelligence Artificielle, Lyon, France. 2012.
- [52] Wang,F., *A knowledge-based vision system for detecting land change at urban fringes*. IEEE Transactions on Geoscience and Remote Sensing, vol. 31, pp. 136–145. 1993.
- [53] Lambin, E. F., et Strahler, A. H., *Indicators of land-cover change for changevector analysis in multitemporal space at coarse spatial scales*. International Journal of Remote Sensing, vol. 15, pp. 2099–2119. 1994.
- [54] Lawrence, R. L., et Ripple, W. J., , *Calculating change curves for multitemporal satellite imagery: Mount St. Helens 1980–1995*. Remote Sensing of Environment, vol. 67, pp. 309–319. 1999.
- [55] Hussin, Y. A., De Gier, A., 1994, *Forest cover change detection analysis using remote sensing: a test for the spatially resolved area production model*. Fifth European Conference and Exhibition on Geographic Information Systems, EGIS'94 Proceedings.
- [56] E. Chuvieco, *Integration of linear programming and gis for land-use modeling*, International Journal of Geographical Information Systems, vol. 7, no. 1, pp. 71-83. 1993.
- [57] M. Weinberg, C. L. Kling, et J. E. Wilen, *Water markets and water quality*, American Journal of Agricultural Economics, vol. 75, no. 2, pp. 278-291. 1993.
- [58] R. G. Cromley et D. M. Hanink, *Coupling land-use allocation models with raster gis*, Journal of Geographic Systems, vol. 1, no. 2, pp. 137-153. 1999.
- [59] T. Houet, L. Hubert-Moy, et G. Mercier, *A neural network method to model spatial and temporal changes in remote sensing : a case study on the winter land cover in brittany*, Cybergeog 271, 2003.
- [60] G. Lajoie et A. Hagen-Zanker, *La simulation de l'étalement urbain à la réunion : apport de l'automate cellulaire metronamica pour la prospective territoriale*, Cybergeog : European Journal of Geography, Systmes, Modlisation, Gostatistiques, document 405, URL : [http ://cybergeog.revues.org/index11882.html](http://cybergeog.revues.org/index11882.html) (2007).
- [61] K. Saheb Ettabaa, *Vers une modélisation spatio-temporelle de scènes en imagerie satellitale*, Ph.D. Thesis, ITI Brest, 2007.
- [62] Largouet C., *Aide à l'interprétation d'une séquence d'images par la modélisation de l'évolution du système observé*, Thèse de doctorat, université de Rennes I, Novembre 2000.
- [63] P. Heas and M. Dateu, *Modeling trajectory of dynamic clusters in image time-series for spatio-temporal reasoning*, IEEE Transactions on Geoscience and Remote Sensing, vol. 43, no. 7, pp. 1635-1647. 2005.
- [64] Marengoni M., Hansonm M., Zilberstein S., et Riseman E, *Decision Making and Uncertainty Management in a 3D Reconstruction System*, Juillet 2003.
- [65] Kumar V.F et Desai U.B., *Image Interpretation Using Bayesian Networks*, IEEE Transaction on Patern Analysis and machine Intelligence, vol. 18, n1, janvier 1996.

- [66] Singhalt A., Luo S J., et Brown C, *A Multilevel Bayesian Network Approach to Image Sensor Fusion*, Department of Computer Science Imaging Science Division University of Rochester Rochester, NY 14627. 2003.
- [67] Heas, P. *Apprentissage Bayésien de Structures Spatio-Temporelles : application à la fouille visuelle de séries temporelles d'images de satellites*, PhD thesis, Ecole Nationale Supérieure de l'Aéronautique et de l'Espace. 2005.
- [68] Gueguen, L. et Datcu, M. (). *Spatio-Temporal Structures Characterization Based on Multi-Information Bottleneck*, ESA-EUSC 2006: Image Information Mining for Security and Intelligence, Madrid. 2006.
- [69] Giros, A. (2006). *Comparison of Partitions of Two Images for Satellite Images Time Series Segmentation*, IEEE International Geoscience And Remote Sensing Symposium, Denver, USA, pp. 2592–2595.
- [70] Daoudi K., Fohr D., et Antoine C, *Réseaux Bayésiens Dynamiques pour la Reconnaissance Multi-Bandes de la Parole*, XXIVèmes Journées d'Étude sur la Parole, Nancy, 24-27 juin 2002.
- [71] Hallouli K., Likforman-Sulem L., Marc Sigelle M., *Reconnaissance de caractères manuscrits par Réseaux Bayésiens Dynamiques*, CIFED 2004.
- [72] Baghdadi S., G. Gravier, C.H. Demarty, P. Gros *Structure learning in a Bayesian network-based video indexing framework*, IEEE Int. Conf. on Multimedia and Expo, ICME'08, Germany, June 2008.
- [73] Rabiner, L. R. *A tutorial on hidden Markov models and selected applications in speech recognition*. Proc. IEEE, 1989.
- [74] Al Ani T., et Guellif H., *Modèles de Markov cachés- théorie et techniques de base*, Research report No. 2196, Feb. 1994, INRIA.
- [75] Fine Y., Singer Y., et Tishby N., *The hierarchical hidden markov model: analysis and applications*. Machine Learning, vol. 32, pp. 41-62. 1998.
- [76] Brand M., Oliver N., Pentland A., *Coupled hidden Markov models for complex action recognition*, in: IEEE International Conference on Computer Vision and Pattern Recognition, pp. 994–999. 1997.
- [77] Nefian A.V., Liang L., Pi X., Liu X., Mao C., et Murphy K., *A coupled HMM for audio-visual speech recognition*, in: Proceedings of ICASSP'02, 2002.
- [78] Xie L., Ye Z., *The JEWEL audio visual dataset for facial animation*, URL [\\_http://www.cityu.edu.hk/remt/mouth-synching/jewel.htm](http://www.cityu.edu.hk/remt/mouth-synching/jewel.htm)\_.F
- [79] W., Pieczynski, *Chaînes de Markov Triplet*, C. R. Acad. Sci. Paris, Ser. I 335, pp. 275–278. 2002.
- [80] Lazri M., Ameer S. et Haddad B., *Analyse de données de précipitations par approche markovienne*, Larhyss Journal, ISSN 1112-3680, n° 06, Décembre 2007.
- [81] Mari JF., et Le Ber F., *Temporal and Spatial Data Mining with Second-Order Hidden Markov Models*. Soft Computing, vol. 10, n°5, pp. 406 – 414. 2006.
- [82] [http://www.irit.fr/ACTIVITES/EQ\\_TCI/EQUIPE/dalle/IRR/12-Mesures.pdf](http://www.irit.fr/ACTIVITES/EQ_TCI/EQUIPE/dalle/IRR/12-Mesures.pdf)

- [83] Slimane M., Aupetit S., et Monmarché N., *Utilisation des Chaînes de Markov Cachées à Substitution de Symboles pour l'apprentissage et la reconnaissance robuste d'images*, 2005.
- [84] Aurdal L., Huseby RB., Eikvil L., et Solberg R., *Use of Hidden Markov Models and Phenology for Multitemporal Satellite Image Classification: Applications to Mountain Vegetation Classification*, In Proceedings of the International Workshop on Analysis Multi-Temporal Remote Sensing Images, 16–18 May, Biloxi, MI (Piscataway, NJ: IEEE), pp. 220–224. 2005.
- [85] Pieczynski W., *Triplet Markov chains and image segmentation*, draft of chapter 4 in Inverse problems in Vision and 3D Tomography, A. Mohammed-Djafari ed., Wiley, 2010.
- [86] Carincotte C., Derrode S. et Bourennane S., *Unsupervised change detection non SAR images using fuzzy hidden Markov chains*, IEEE Trans. Geosci. Remote Sensing, 2005.
- [87] Derrode S. et Pieczynski W., *Signal and image segmentation using pairwise Markov chains*, IEEE Trans. Signal Processing, vol. 52, pp. 2477–2489, September 2004.
- [88] Wijanarto, *Application of Markov change detection technique for detecting Landsat ETM derived land cover change over Banten Bay*, Jurnal Ilmiah Geomatika Vol. 12, No. 1 Agustus 2006.
- [89] Essid H, Farah IR., et Barra V., *Modèle hybride spatio-temporel d'analyse d'images satellitaires à base de réseaux Bayésiens dynamiques*, 6<sup>ème</sup> Colloque sur l'Optimisation et les Systèmes d'Information Annaba, 2009.
- [90] Essid H, Farah IR, et Barra V, *Système d'interprétation spatio-temporelle d'images satellitaires à base de modèle de Markov caché hiérarchique*, Actes Spatial Analysis and GEOMatics - SAGEO'09, 25-27 Novembre 2009, Paris, France.
- [91] Essid H, Farah IR, Barra V., *Analyse de la variation spatio-temporelle des objets dans des images satellitaires à base de modèles de Markov cachés couple*, Actes de la conférence Extraction et Gestion des Connaissances, Hammamet, Tunisie, 26-29 janvier 2010
- [92] Essid H, Farah I.R. et Barra V., *Spatio-temporal modeling based on Hidden Markov Model for Object Tracking in Satellite Imagery*, Actes de la conference Sciences of Electronics, Technologies of Information and Telecommunications SETIT. Sousse, Tunisie, 2012.
- [93] Bo-Yeong, K., Dae-Won, K. And Qing, L., , *Spatial Homogeneity-Based Fuzzy c-Means Algorithm for Image Segmentation*, Fuzzy Systems and Knowledge Discovery, Lecture notes in computer science, vol. 36, n°13, pp. 462-469. 2005.
- [94] Lefèvre S., *Une nouvelle approche pour la classification non supervisée en segmentation d'image* Dans : P. Gancarski J.G. Ganascia, éditeur : Revue des Nouvelles Technologies de l'Information, Numéro Thématique Extraction et Gestion des Connaissances (EGC'2009), volume RNTI-E-15, pages 127–138. Cépaduès Editions, Strasbourg, France, Janvier 2009.
- [95] Lorette A., *analyse de texture par méthodes markoviennes et par morphologie mathématique : Application à l'analyse des zones urbaines sur les images satellitaires*, Thèse de Luniversité de Nice-Sophia Antipolis-1998.
- [96] Bessai F.Z., Krelifaoui M. et Guergab Mohamed, *Utilisation des cartes auto-organisatrices de Kohonen dans la recherche documentaire*, CEntre de Recherche sur l'Information Scientifique et Technique (CERIST). Laboratoire Base de Données et Système d'Information. Ben-Aknoun, Alger, Algérie

- [197] Youssoufi S, et Antoni J., *La simulation comme outil prospectif en aménagement urbain*, théma, umr 6049 du cnrs-Université de Franche-Comté.
- [198] Essid H, Farah I.R. et Barra V., *Towards an intelligent predictive model for analyzing spatio-temporal satellite image based on hidden Markov chain*, soumis à Journal of Applied Remote Sensing pour révision.
- [199] Essid H., Mantouch F., Farah I.R. et Barra V., *Modélisation spatio-temporelle à base de réseaux bayésiens dynamiques pour le suivi d'objets en imagerie satellitale: Cas de forêts*, Actes de la conférence EGC'11 Extraction et Gestion des Connaissances, Brest, France. 2011.
- [100] Essid H, Sallami A., Farah IR., et Barra V., *Monitoring intra-urban changes with Hidden Markov Models using the spatial relationships*, ICGST-GVIP Journal, Volume 12, Issue1, April 2012.
- [101] Haralick R.M., *Statistical and structural approaches to texture*, IEEE proceeding, Vol. 67, pp.786-804, mai 1979.
- [102] Laroche B., Thorette J. et Lacassin J.Cl., *L'artificialisation des sols: pressions urbaines et inventaire des sols*, étude et Gestion des Sols, vol. 13, 3, - pages 223 à 235. 2006.
- [103] Essid H, Ben Abbes A., Farah I.R. et Barra V., *Vers une modélisation Spatio-temporelle intelligente à base de modèle de Markov caché pour le suivi de la variation des zones urbaines*, Taima'11, Traitement et Analyse de l'Image Méthodes et Traitements, Hammamet du 03 au 08 Octobre 2011.
- [104] Faïz S., et Mahmoudi K., *Extraction des connaissances pour l'enrichissement des bases de données géographiques*, Extraction et gestion des connaissances (EGC'2005), Actes des cinquièmes journées Extraction et Gestion des Connaissances, Paris, France, 18-21 janvier 2005, Vol.2. 2005.