

# Table des matières

<b>Présentation</b>	<b>6</b>
<b>1 L'imagerie radar</b>	<b>9</b>
1.1 Introduction . . . . .	9
1.1.1 Aperçu historique . . . . .	10
1.1.2 Spécificités et applications . . . . .	10
1.2 Système imageur . . . . .	12
1.2.1 Acquisition des images . . . . .	13
1.2.2 Déformations géométriques . . . . .	15
1.3 Statistiques des images ROS . . . . .	16
1.3.1 L'équation radar . . . . .	16
1.3.2 Statistique du chatoiement totalement développé en 1-vue . . . . .	18
1.3.3 Statistique du chatoiement totalement développé en L-vues . . . . .	21
1.3.4 Statistique du chatoiement non gaussien . . . . .	23
1.3.5 Statistique du chatoiement non totalement développé . . . . .	25
1.3.6 Conclusion sur les statistiques du premier ordre . . . . .	25
1.3.7 Statistiques du deuxième ordre . . . . .	25
1.3.8 Format des images ERS-1 . . . . .	26
1.4 Conclusion . . . . .	27
<b>2 Détecteurs de lignes en imagerie ROS</b>	<b>28</b>
2.1 Présentation du problème . . . . .	28
2.2 Le détecteur de contours $Dc1$ . . . . .	30
2.2.1 Définition de $Dc1$ . . . . .	31
2.2.2 Probabilités de détection et de fausse alarme de $Dc1$ . . . . .	33
2.3 Le détecteur de lignes $D1$ . . . . .	33
2.3.1 Définition de $D1$ . . . . .	33
2.3.2 Probabilités de détection et de fausse alarme de $D1$ . . . . .	35
2.3.3 Validation empirique sur une zone-test pour $D1$ . . . . .	37

2.3.4	Cas de plusieurs directions . . . . .	39
2.4	Le détecteur de contours Dc2 . . . . .	39
2.4.1	Définition de Dc2 . . . . .	39
2.4.2	Probabilités de détection et de fausse alarme de Dc2 . . . . .	41
2.4.3	Application du détecteur de contours Dc2 . . . . .	42
2.5	Le détecteur de lignes D2 . . . . .	45
2.6	Comparaison des détecteurs D1 et D2 . . . . .	46
2.7	Fusion des réponses de D1 et D2 . . . . .	49
2.8	Des pixels aux segments . . . . .	51
2.8.1	Suppression des pixels isolés . . . . .	51
2.8.2	Transformée de Hough locale . . . . .	51
2.8.3	Obtention des segments . . . . .	53
2.9	Conclusion . . . . .	54
<b>3</b>	<b>Une méthode de connexion markovienne</b>	<b>55</b>
3.1	Présentation du problème . . . . .	55
3.2	Définition du graphe . . . . .	56
3.3	Distributions conditionnelles, a priori, et a posteriori . . . . .	60
3.3.1	Distribution conditionnelle du champ d'observations $p(D L)$ . . . . .	60
3.3.2	Probabilité a priori du champ d'étiquettes $p(L)$ . . . . .	63
3.3.3	Probabilité a posteriori du champ d'étiquettes $p(L D)$ . . . . .	64
3.4	Minimisation de l'énergie . . . . .	66
3.4.1	Remarques sur le recuit simulé . . . . .	66
3.4.2	Recuit simulé dédié au graphe des segments . . . . .	66
3.5	Analyse de l'influence des paramètres . . . . .	67
3.6	Repositionnement des segments . . . . .	69
3.7	Conclusion . . . . .	71
<b>4</b>	<b>Applications</b>	<b>73</b>
4.1	La détection du réseau routier . . . . .	73
4.1.1	Intérêt et objectif . . . . .	73
4.1.2	Aspect des routes sur des images ROS . . . . .	75
4.1.3	Méthode de détection . . . . .	76
4.1.4	Résultats . . . . .	79
4.1.5	Les limites de la méthode . . . . .	81
4.2	La détection du réseau hydrographique . . . . .	92
4.2.1	Présentation . . . . .	92
4.2.2	Méthode de détection . . . . .	93

4.2.3	Le repositionnement du fleuve . . . . .	100
4.2.4	Résultats . . . . .	101
4.3	La détection des zones de relief marqué . . . . .	101
4.3.1	Présentation . . . . .	101
4.3.2	Méthode de détection . . . . .	101
4.3.3	Résultats . . . . .	105
4.4	Conclusion . . . . .	105
 <b>II Outils pour l'analyse de régions</b>		<b>107</b>
 <b>5 Le filtrage du chatoiement</b>		<b>109</b>
5.1	Présentation . . . . .	109
5.2	Quelques filtres classiquement utilisés . . . . .	110
5.2.1	Les filtres non spécifiques . . . . .	110
5.2.2	Les filtres adaptatifs . . . . .	110
5.2.3	Les filtres adaptatifs avec modélisation de la scène . . . . .	111
5.2.4	L'amélioration du calcul des statistiques . . . . .	112
5.2.5	Le filtrage multi-temporel . . . . .	114
5.3	Régularisation avec prise en compte des discontinuités . . . . .	115
5.3.1	Introduction . . . . .	116
5.3.2	Définition du processus bord $b_{r,s}$ sur les images radar . . . . .	118
5.3.3	Méthodologie de l'étude . . . . .	119
5.3.4	Distribution gaussienne et fonction $\mathcal{H}$ quadratique . . . . .	120
5.3.5	Distribution gamma généralisée et fonction $\mathcal{H}$ quadratique . . . . .	123
5.3.6	Distribution gamma généralisée et fonction $\mathcal{H}$ adaptée . . . . .	124
5.3.7	Comparaisons entre quelques filtres . . . . .	126
5.3.8	Perspectives . . . . .	128
5.4	Conclusion . . . . .	129
 <b>6 Segmentation des images radar</b>		<b>130</b>
6.1	Quelques méthodes . . . . .	130
6.2	Une méthode markovienne . . . . .	132
6.2.1	Présentation . . . . .	132
6.2.2	Aspects pratiques . . . . .	134
6.2.3	Résultats . . . . .	135
6.2.4	Préservation des objets linéaires . . . . .	136
6.3	Détection des zones de parcellaire dense . . . . .	142
6.3.1	Terme d'attache aux données . . . . .	143

6.3.2	Terme contextuel . . . . .	146
6.3.3	Résultats . . . . .	146
6.4	Conclusion . . . . .	147
<b>7</b>	<b>Texture en imagerie radar</b>	<b>149</b>
7.1	Discriminateurs texturaux en imagerie radar . . . . .	149
7.1.1	Statistiques du premier ordre . . . . .	150
7.1.2	Décomposition de l'histogramme à l'aide de polynômes de Laguerre	153
7.1.3	Modèle multiplicatif auto-régressif (MAR) . . . . .	155
7.1.4	Comparaison des résultats des trois méthodes . . . . .	163
7.1.5	Application à la détection des zones homogènes . . . . .	164
7.1.6	Application à la détection des zones industrielles . . . . .	165
7.2	Identification des zones urbaines . . . . .	168
7.2.1	Analyse de la queue de l'histogramme . . . . .	168
7.2.2	Analyse de la densité de très forts réflecteurs . . . . .	169
7.3	Conclusion et perspectives . . . . .	170
<b>III</b>	<b>Outils pour l'interprétation de la scène</b>	<b>173</b>
<b>8</b>	<b>Fusion des informations par la théorie des croyances</b>	<b>175</b>
8.1	Introduction . . . . .	175
8.1.1	Les systèmes à base de règles . . . . .	176
8.1.2	Les méthodes fondées sur des graphes . . . . .	177
8.1.3	Les méthodes de fusion numérique . . . . .	178
8.1.4	Démarche proposée . . . . .	178
8.2	Rappels sur la théorie des croyances . . . . .	180
8.2.1	Masse, crédibilité, plausibilité . . . . .	181
8.2.2	Règle orthogonale de Dempster . . . . .	182
8.2.3	Critère de décision . . . . .	184
8.3	Application de la théorie des croyances pour l'interprétation des images radar	184
8.3.1	Définition des régions . . . . .	185
8.3.2	Définition des fonctions de masses . . . . .	186
8.3.3	Combinaison . . . . .	198
8.3.4	Avantages de la théorie des croyances . . . . .	200
8.3.5	Aspects pratiques . . . . .	202
8.4	Classification par régularisation markovienne sur le graphe d'adjacence . .	203
8.5	Résultats . . . . .	205
8.5.1	Résultats sur des images ERS-1 . . . . .	205

---

8.5.2	Résultat sur des images SIR-C/X-SAR . . . . .	207
8.5.3	Résultat sur des images RADARSAT . . . . .	209
8.6	Conclusion . . . . .	209
<b>Conclusion</b>		<b>222</b>
<b>Annexes</b>		<b>227</b>
<b>A Base de données</b>		<b>229</b>
A.1	Introduction . . . . .	229
A.2	Scène des Pays-Bas . . . . .	231
A.3	Scène de Bretagne . . . . .	237
A.4	Scène de Paris . . . . .	240
A.5	Scène d'Aix-en-Provence . . . . .	241
A.6	Scène de Guyane . . . . .	241
<b>B Appariement de zones urbaines</b>		<b>250</b>
B.1	Introduction . . . . .	250
B.2	Méthode utilisée . . . . .	250
B.3	Détection des agglomérations dans l'image radar et dans la carte . . . . .	253
B.3.1	Détection des agglomérations de l'image radar . . . . .	253
B.3.2	Détection des agglomérations de la carte . . . . .	253
B.4	Résultats de recalage par mise en correspondance des agglomérations . . . . .	256
B.4.1	Image de Mantes . . . . .	256
B.4.2	Image de Lorient . . . . .	258
B.4.3	Image d'Aix-en-Provence . . . . .	258
B.5	Conclusion . . . . .	258

# Présentation

Les capteurs satellitaires radars connaissent de nos jours un développement considérable, comme le prouve le lancement de RADARSAT, satellite canadien, en 1995, après ceux des satellites européens (ERS-1 et -2) et japonais (JERS-1). Cet essor s'explique en grande partie par les résolutions atteintes grâce à l'ouverture synthétique des antennes, qui sont de l'ordre de la dizaine de mètres. Les données radars diffusées peuvent ainsi rivaliser avec les images fournies par les capteurs optiques comme SPOT ou LANDSAT. En outre, leurs propriétés spécifiques ouvrent de nouvelles perspectives dans le domaine de la télédétection. Tout d'abord, leur aptitude à traverser la couche nuageuse en fait des outils privilégiés pour l'étude des zones tropicales. Ensuite, leur capacité à pénétrer la végétation et certains sols en fait des outils complémentaires à ceux déjà existants pour toutes les applications cartographiques. Enfin, des techniques nouvelles ont vu le jour, comme l'interférométrie fondée sur l'information de la phase du signal.

Conjointement à ces acquisitions massives de nouvelles données, de nombreuses études ont été menées pour leur exploitation suivant deux grands axes. Tout d'abord, plusieurs applications ont été testées sur des projets pilotes pour assurer aux images des débouchés commerciaux et attirer des utilisateurs potentiels. Ensuite, de nombreuses recherches ont porté sur le développement d'outils capables de faciliter la photo-interprétation et le traitement semi-automatique des données. Plusieurs applications sont pratiquement opérationnelles : la surveillance de certaines cultures comme le riz, le routage des bateaux, la production de modèles numériques de terrain par interférométrie, etc. Néanmoins, les images radar font toujours l'objet d'un grand nombre de recherches motivées par la difficulté d'exploitation de l'information délivrée. C'est le cas de l'information de phase en raison du bruit dont elle est entachée et de son repliement modulo  $2\pi$  ; elle procure cependant une connaissance précise de l'altitude. Quant à l'information de l'amplitude, elle est rendue moins lisible par le phénomène de chatoiement (speckle) présent sur les images radar, et par les déformations géométriques liées au processus d'acquisition de l'image. Aussi, la pérennité de l'intérêt qui se manifeste aujourd'hui pour ces nouvelles sources d'information est-elle liée de façon drastique aux outils d'interprétation et d'exploitation qui l'accompagneront.

Ainsi, le travail de cette thèse s'inscrit dans les efforts de recherche qui sont actuellement entrepris pour faciliter l'interprétation des images radar. De nombreuses recherches portent sur le filtrage des images radar, ou sur la fusion des données radar avec celles issues d'autres capteurs. Au contraire de ces approches, l'originalité de notre travail est de porter directement sur le développement d'une méthode d'analyse de scènes, permettant de réaliser une interprétation partielle mais automatique des images radar. Certains des outils développés au cours de ce travail peuvent être utilisés pour des applications spécifiques, mais l'objectif poursuivi ici est clairement de donner une classification sémantique de l'image en détectant les objets structurant le paysage : les réseaux, hydrographique et routier, le milieu urbain, les zones de mer ou de forêt, les zones de relief. Nous nous situons donc au niveau de l'aide à l'interprétation, en fournissant au photo-interprète une cartographie élémentaire de l'image faisant ressortir les grandes entités sémantiques.

Nous nous sommes fixés plusieurs objectifs lors de l'élaboration de ce travail. Notre motivation principale est de mesurer l'apport réel des images radar et d'exploiter au maximum les informations intrinsèques qu'elles délivrent. Ainsi, la nature et le nombre de données dont nous pouvons disposer ont été volontairement restreints : seule l'image radar est utilisée, indépendamment de toute carte ou de toute autre source d'information satellitaire. Des prolongements possibles à cette thèse seront bien sûr l'emploi de plusieurs images - soit pour travailler sur une image de meilleure qualité grâce au filtrage multi-temporel, soit pour fusionner des informations provenant de sources différentes -, et l'emploi d'une connaissance a priori de haut niveau comme une carte. De plus, le signal radar dont nous disposons n'est pas le signal complexe délivré par le capteur, mais un signal en amplitude, souvent moyenné pour améliorer la lisibilité de l'image. Les images utilisées seront principalement des produits Precision Images -PRI- délivrés par l'agence spatiale européenne (ESA) et provenant du capteur RSO du satellite ERS-1. Enfin, nous nous sommes fixés comme contrainte de développer des outils automatiques ou semi-automatiques, et ce souci a toujours guidé nos choix. L'intervention de l'utilisateur a été limitée le plus possible et les paramètres, lorsqu'il en intervenait, ont été choisis de façon à être valides pour un grand nombre d'images provenant d'un même capteur.

A l'image du travail qu'il relate, ce rapport s'articule en deux grandes étapes : une étape de développement d'opérateurs "élémentaires" permettant d'obtenir des informations sur les différentes classes thématiques et une étape d'interprétation fusionnant les réponses obtenues.

En ce qui concerne la première étape, les outils développés, bien que multiples, peuvent être scindés en deux parties. Tout d'abord, nous avons mis au point des opérateurs visant à l'extraction des éléments linéaires de l'image, comme les réseaux routiers et fluviaux ou les lignes brillantes caractérisant les zones de relief. Pour ce faire, des détecteurs de lignes ont été proposés et étudiés, et une méthode de connexion markovienne de segments a été développée. L'utilisation conjointe de ces outils pour détecter les réseaux ou la présence de relief dans des cas particuliers d'orientation est présentée. Ces techniques font l'objet de la partie I de ce rapport.

Ensuite, nous avons abordé l'extraction d'objets surfaciques caractéristiques, comme les zones industrielles ou les régions de mer, de végétation ou de parcellaire. Après une discussion sur le filtrage, qui peut être conçu comme une solution aux problèmes d'interprétation spécifiques des images radar, une méthode de segmentation a été présentée et des discriminateurs texturaux étudiés. Là encore, la combinaison de ces outils permet d'extraire de nouveaux éléments d'interprétation. Ces méthodes, qui sont moins originales en ce qui concerne la segmentation et les discriminateurs texturaux que la première partie mais tout autant nécessaires pour la suite, constituent la partie II de ce rapport (fig. 0.1).

La troisième partie de ce rapport porte sur la définition d'une méthode globale d'interprétation, qui constitue la seconde étape de notre travail. Il s'agit alors de fusionner les différentes informations extraites, en tirant parti de leur redondance éventuelle ou de leur contradiction. La méthode proposée s'appuie sur la théorie des croyances de Dempster et Shafer, dont la grande souplesse permet d'exploiter au mieux les capacités et les limites des opérateurs développés.

La démarche proposée pour l'interprétation automatique des images satellitaires de radar à ouverture synthétique sera illustrée tout au long de ce rapport sur des images réelles. Il s'agira principalement d'images acquises par le satellite européen ERS-1, mais des résultats seront également présentés sur des images RADARSAT et SIR-C / X-SAR. La base de données utilisée au cours de ce travail est décrite en Annexe A où les images sont présentées, accompagnées des cartes correspondantes. La difficulté de détection des éléments thématiques est également évaluée. Nous invitons le lecteur à se référer à cette annexe pour comparer les résultats qui sont présentés tout au long de cette thèse aux images originales et aux cartes.

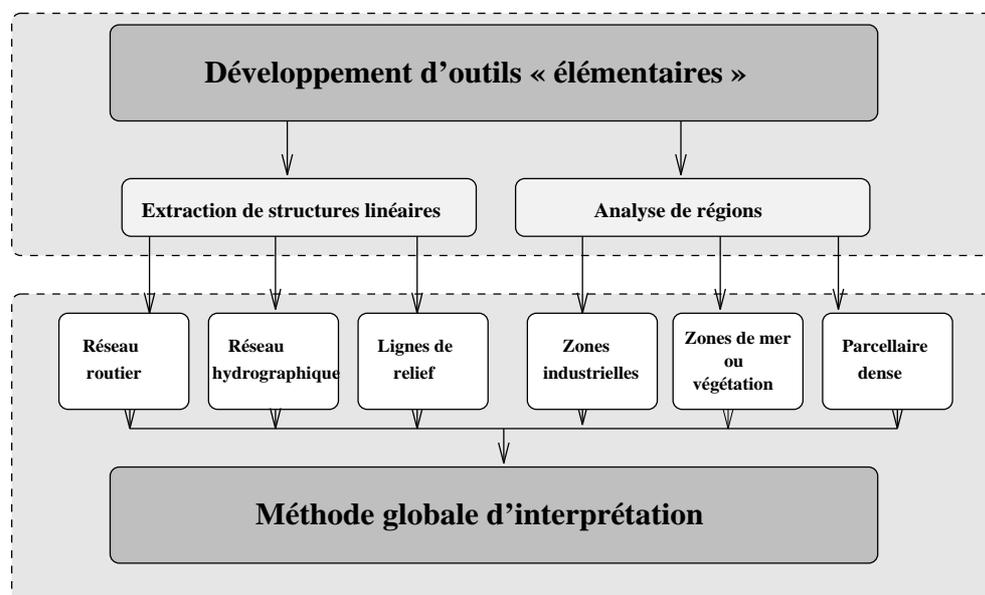


FIG. 0.1 – Organisation de la thèse et du rapport. La première partie encadrée correspond aux parties I et II de ce rapport, et la deuxième partie à la partie III.

# Chapitre 1

## L'imagerie radar

*En guise d'introduction à l'imagerie radar, ce chapitre tend à présenter brièvement l'évolution des capteurs radars, ainsi que leurs applications actuelles. Outre les principes d'acquisition des données, de la compression d'impulsion et de la synthèse d'ouverture, y seront également exposées les distributions statistiques décrivant les images ROS, ainsi que les hypothèses et les différentes approches qui y conduisent.*

### 1.1 Introduction

Le radar imageur a pour principe l'émission d'ondes électro-magnétiques dont la rétro-diffusion est ensuite enregistrée (fig.1.1). Le domaine de fréquences utilisé est celui des hyper-fréquences, de 0,8 à 30 GHz, et correspond à des longueurs d'onde de l'ordre du centimètre (micro-ondes). De plus, pour les applications d'imagerie satellitaire, les radars sont le plus souvent à visée latérale et monostatiques, c'est à dire que l'antenne de réception et celle d'émission se situent au même endroit (fig.1.1).

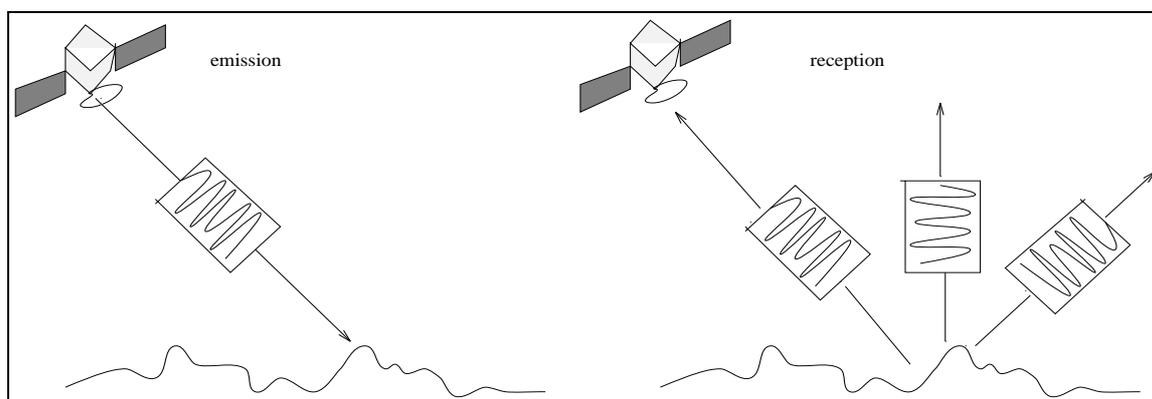


FIG. 1.1 – Principe du radar (inspiré de la page Web du Jet Propulsion Laboratory <http://southport.jpl.nasa.gov/>)

### 1.1.1 Aperçu historique

Si les premiers radars font leur apparition durant la seconde guerre mondiale, c'est avant tout grâce à leur capacité à situer des cibles, et en particulier des bateaux, fortement rétro-diffuseurs. En effet, en se montrant aptes à localiser des objectifs grâce au temps écoulé entre l'émission et la réception d'ondes électro-magnétiques à partir d'un avion [Hard-96], les radars s'avèrent de précieux auxiliaires des armées en campagne. Aussi, lorsque cesse le conflit, leur développement demeure une priorité militaire qui débouche bientôt sur les premières tentatives d'imagerie. Avec les *Brute Force Radars*, la résolution reste très médiocre et permet peu d'applications [Lebe-90], mais en 1950, la théorie de l'antenne à ouverture synthétique proposée par Wiley de la Goodyear Aircraft Corporation amène une amélioration considérable de la résolution [Curl-91] (radars à ouverture synthétique notés ROS ou SAR).

Suite à ces résultats qui ouvrent de nouvelles perspectives, le développement des systèmes imageurs radars devient civil et s'accélère. En 1978, le satellite américain SEASAT est lancé avec un radar à bord ; il est suivi par plusieurs missions de la navette spatiale américaine : SIR (Shuttle Imaging Radar)-A en 1981, SIR-B en 1984 et SIR-C en 1994. Plusieurs satellites spatiaux sont lancés avec des systèmes imageurs radars : ERS-1 en 1991 (European Remote Sensing Satellite), Almaz satellite russe en 1991, JERS-1 en 1992 (Japanese Earth Resources Satellite), ERS-2 en 1995, et RADARSAT satellite canadien en 1995 [Way-91].

### 1.1.2 Spécificités et applications

Les systèmes radars sont des systèmes actifs qui ont leur propre source d'illumination. Par conséquent, ils sont capables de produire des images de jour comme de nuit, contrairement aux systèmes optiques qui dépendent de l'éclairage des zones imagées. De plus, et c'est la raison principale de l'engouement pour ce capteur, l'utilisation de micro-ondes permet la pénétration des nuages et de la pluie. Ainsi les capteurs radars ont des performances indépendantes du temps, alors que l'utilisation de SPOT<sup>1</sup>, par exemple, est rendue pratiquement impossible par la présence de nuages sur certaines zones tropicales. Par ailleurs, leurs perspectives totalement différentes de celles des systèmes optiques (visée latérale et surtout échantillonnage en distance) apportent des informations souvent très complémentaires. En outre, les systèmes radars ont la possibilité de pénétrer la végétation ainsi que certaines surfaces, et le signal rétro-diffusé est caractéristique des propriétés électro-magnétiques et physiques de la surface observée.

Un autre aspect important des systèmes radars est leur potentiel multi-spectral (plusieurs bandes X, L, ou C peuvent être utilisées) et multi-polarisations (émission avec une certaine polarisation et réception avec une autre, aspect exploité par les radars polarimétriques comme AirSAR du Jet Propulsion Laboratory).

Utilisés depuis une dizaine d'années, les capteurs spatiaux radars ont d'ores et déjà de nombreux champs d'applications [LAS-95].

---

1. Système Probatoire d'Observation de la Terre, série de satellites français opérant dans plusieurs bandes spectrales optiques

Parmi les applications terrestres opérationnelles, on peut distinguer quatre grands groupes :

- *L'exploitation des ressources agricoles et forestières.* Citons la surveillance et le suivi de la croissance des cultures [LeTo-97], ainsi que la prévision des récoltes (en effet le signal rétro-diffusé varie avec l'âge des plants), ou bien encore le contrôle de la proportion terres cultivées / jachère [Boum-92]. Néanmoins, il s'agit d'une utilisation conjointe des données radar et optique. Par ailleurs, la surveillance des forêts tropicales est possible sur les données radar grâce à la différence de textures entre les zones de forêts vierges et celles clairessemées [Stof-95] [Oliv-94b]. Notons que le suivi des défrichements sur les zones tropicales est difficile avec des capteurs optiques à cause de la présence de nuages.
- *Les applications géologiques et les prospections minières.* En effet, l'imagerie radar permet de rendre compte de façon très précise des structures géologiques de surface, ce qui concerne notamment l'exploitation des ressources en hydrocarbures.
- *La prévention et le suivi des catastrophes naturelles,* en particulier la surveillance des inondations. Les zones inondées, lisses par rapport à la longueur d'onde, apparaissent clairement sous formes de zones particulièrement sombres (en l'absence de vent et s'il ne subsiste pas de végétation émergeant de l'eau) dans les images radar.
- *La cartographie,* qui reste dans un domaine pré-opérationnel ou de recherche (comme la détection des zones urbaines [Goui-96], des réseaux routiers ou fluviaux, qui font en partie l'objet de cette thèse).

Pour toutes ces applications, opérationnelles ou pré-opérationnelles, se pose le problème des fréquences de passage des satellites et de disponibilité des images.

De nombreuses applications maritimes sont également à un stade opérationnel :

- détection des marées noires,
- surveillance des dégazages sauvages,
- étude du mouvement des glaces [Moct-95] et discrimination des différents types de glaces pour le routage des bateaux dans la banquise en formation,
- prévision de l'état de la mer [Stof-95].

La détection du trait de côte et son évolution font partie des domaines de recherche [Moct-95].

Un autre champ d'investigation est l'étude des planètes recouvertes de nuages. En 1978, la mission Magellan de la NASA a permis d'obtenir les premières images de Venus, et prochainement devrait être lancé un satellite radar autour de la planète Titan complètement recouverte de nuages (mission Cassini) [Lebe-90] [Way-91].

L'imagerie radar dispose également d'un fort potentiel pour toutes les applications de reconstitution du relief. Trois techniques peuvent être exploitées : l'interférométrie [Gold-88] [Prat-90] [Masso-93] [Labr-95] [Trou-96] (cette technique performante constitue un des atouts majeurs de l'imagerie radar par rapport à l'optique), la radarclinométrie [Widl-86a] [Horn-75] [Paqu-96], et la radargrammétrie [Lebe-86] [Rama-86] [Noce-96].

Actuellement en plein essor avec le lancement de nouveaux satellites (RADARSAT en 1996 et EOS prévu pour la fin des années 90), l'imagerie radar est pour de nombreuses applications encore au stade de la recherche. Les potentialités sont nombreuses mais l'exploitation des images est rendue difficile par la présence de chatoiement (ou speckle) qui en limite la lisibilité et que nous présenterons au §1.3.2.

## 1.2 Système imageur

Cette partie décrit succinctement les principes de formation des images radar, sans entrer dans le détail des processeurs ROS. Elle s'appuie sur les travaux suivants : [Barb-85] [Lebe-90] [Curl-91] [Lebed-95], auxquelles on pourra se référer.

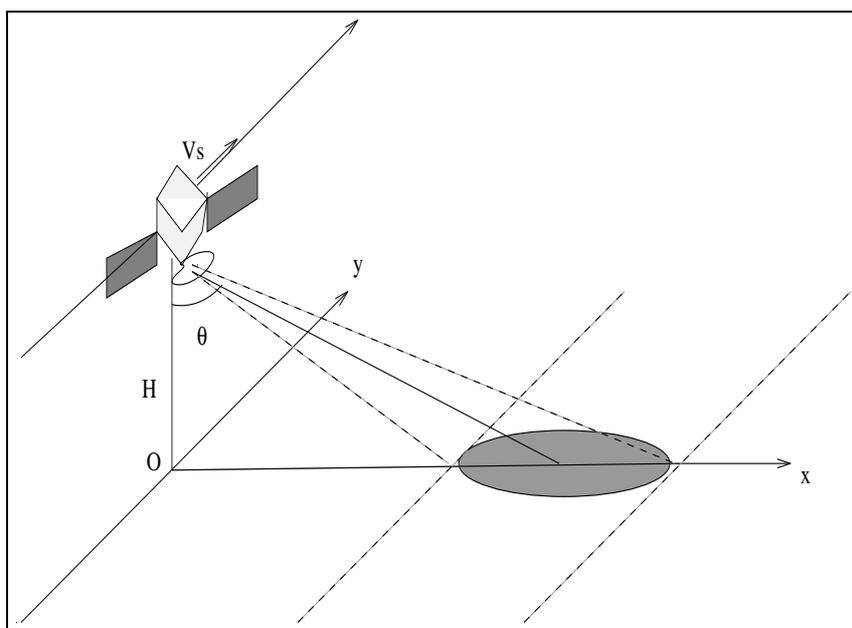


FIG. 1.2 – Le système radar

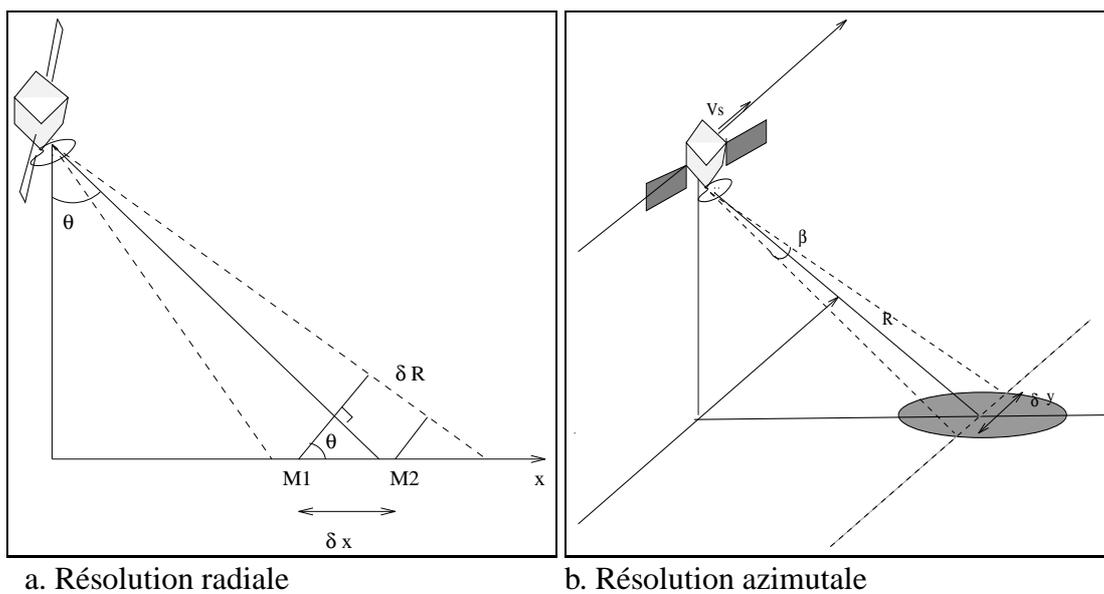


FIG. 1.3 – Résolutions brutes

### 1.2.1 Acquisition des images

Le principe des radars imageurs repose sur l'émission d'ondes électro-magnétiques de fréquence de l'ordre du GHz par une antenne, puis de la réception par cette même antenne des signaux rétrodiffusés par le sol (fig.1.2). Si l'onde émise est une impulsion de durée  $\tau$ , pour que deux cibles ponctuelles  $M_1$  et  $M_2$  au sol soient distinguées, il faut que  $t_2 - t_1 \geq \tau$ , où  $t_i$  est l'instant de réception du signal rétrodiffusé par la cible  $M_i$  (fig.1.3a). En notant  $R_i$  la distance entre le radar et la cible  $M_i$ , on obtient dans le cas limite de l'égalité :

$$\delta R = \frac{c\tau}{2}$$

Et comme  $\delta x = \frac{\delta R}{\sin \theta}$  (fig.1.3) finalement :

$$\delta x = \frac{c\tau}{2 \sin \theta}$$

La résolution obtenue ne dépend donc pas de l'altitude  $H$  du porteur. Dans le cas du satellite ERS-1 avec  $\tau = 37,12\mu s$  et en considérant un sol plan, la résolution est  $\delta x = 14,2\text{km}$ . Cette résolution est considérablement améliorée par la technique de compression d'impulsion. Celle-ci consiste à émettre un "chirp", signal de durée  $\tau$  modulé linéairement en fréquence (i.e  $\Phi = 2\pi(f_c t + \frac{Kt^2}{2})$  en notant  $\Phi$  la phase du signal émis), de largeur de bande  $B = K\tau$ . Après passage dans le filtre adapté, on obtient la résolution [Lebed-95] :

$$\delta x = \frac{c}{2B \sin \theta}$$

Tout se passe avec le filtrage adapté comme si le signal n'était vu qu'avec une durée  $\tau' = \frac{1}{B}$ . Pour ERS-1 (tab.1.1), avec une bande passante  $B = 15.5\text{MHz}$ , on obtient une résolution moyenne<sup>2</sup> au sol de 25m.

La résolution en azimut dépend de la distance radiale  $R$  et de l'ouverture du lobe d'antenne  $\beta_a = \frac{\lambda}{L_a}$  (fig.1.3b) :

$$\delta y = R \frac{\lambda}{L_a}$$

Pour ERS-1, au centre du lobe d'antenne  $R = 853\text{km}$ ,  $\lambda = 5,3\text{cm}$ ,  $L_a = 10\text{m}$ , d'où  $\delta y = 4,5\text{km}$ .

Là encore, cette résolution est très insuffisante pour un système imageur. Elle est améliorée par la technique de la synthèse d'ouverture qui permet d'atteindre une résolution de l'ordre du mètre comparable à celle des systèmes optiques. L'idée est d'utiliser plusieurs positions de l'antenne pour construire l'image. Ainsi, une cible apparaît dans plusieurs impulsions rétrodiffusées, avec pour chacune de ces impulsions un angle différent par rapport au radar en déplacement (fig.1.4a). L'antenne synthétisée en utilisant toutes les informations correspond à une antenne qui est bien plus grande que l'antenne réelle et possède donc une ouverture angulaire bien plus fine.

---

2. En réalité, l'angle  $\theta$  dépend de la position des points à l'intérieur du lobe d'antenne en raison de la rotondité de la terre et la résolution varie de 22,1m à 28,9m lorsqu'on se rapproche du Nadir (point O, fig.1.2) [Queg-94].

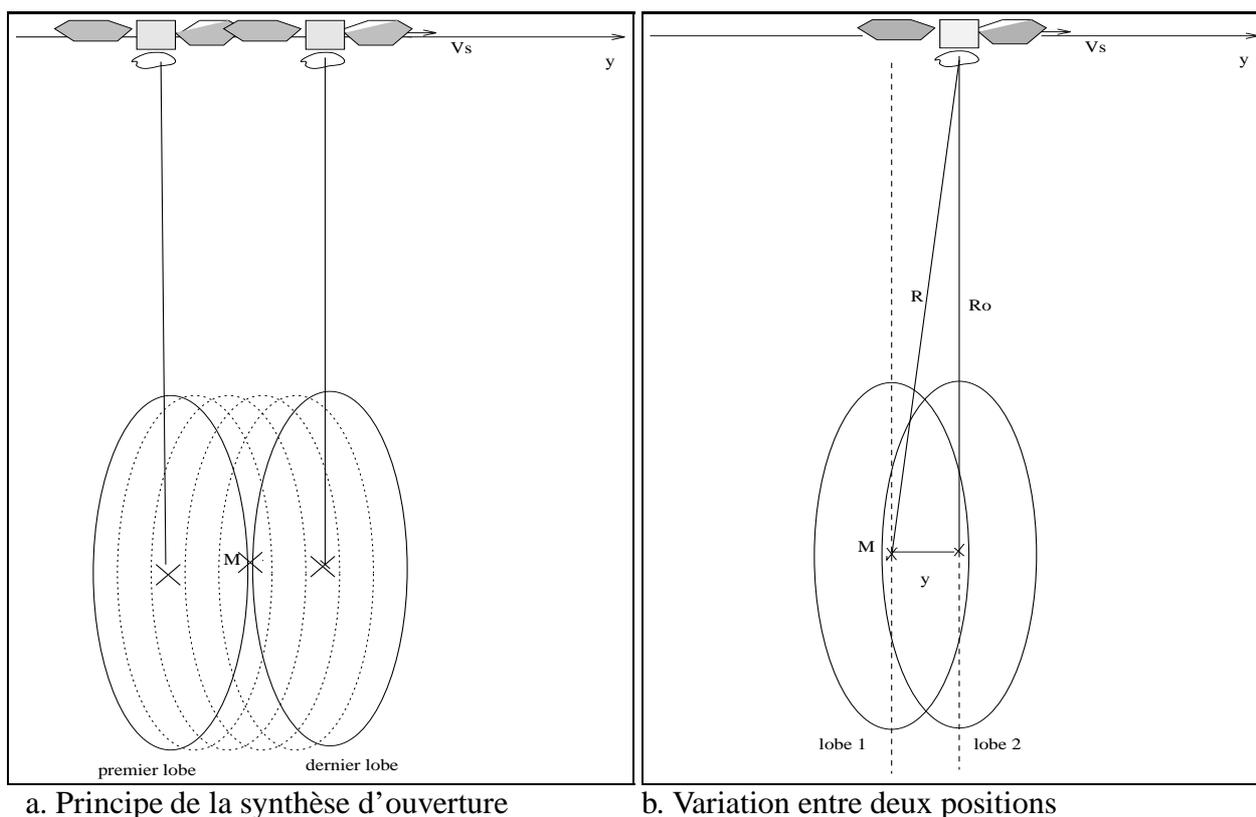


FIG. 1.4 – Principe de la synthèse d'ouverture

Fréquence des impulsions	PRF=1678 Hz
Fréquence centrale de l'onde	$f_o = 5,3$ GHz (bande C)
Longueur d'onde	$\lambda = 5,6$ cm
Bande passante du chirp	$B=15,55$ MHz
Durée du signal	$\tau = 37,12$ $\mu$ s
Dimensions de l'antenne	10 m $\times$ 1 m
Vitesse du satellite	$V_s = 7,5$ km.s <sup>-1</sup>
Angle d'incidence	$\theta = 23^\circ$
Altitude	$H=785$ km
Distance radar - centre du lobe d'antenne	$R_o = 850$ km

TAB. 1.1 – Paramètres du satellite ERS-1

En pratique, une cible pourra être différenciée des autres parce que son déphasage varie, au cours du temps, comme la distance  $R$  qui la sépare du satellite au fur et à mesure que celui-ci se déplace. Soit  $\phi$  la différence de phase entre le signal émis et le signal reçu :

$$\phi = 2\pi f_o \frac{2R}{c}$$

Avec les notations de la figure 1.4b et en considérant  $y$  très petit devant  $R_o$  (distance mini-

male entre la cible et le satellite) :

$$R = R_o + \frac{y^2}{2R_o}$$

D'où :

$$\phi(y) = \frac{2\pi y^2}{\lambda R_o} + k$$

avec  $k$  constante. La fréquence spatiale instantanée s'en déduit :

$$f(y) = \frac{1}{2\pi} \frac{d\phi(y)}{dy} = \frac{2y}{\lambda R_o} = K_a y$$

Tout se passe comme si la fréquence spatiale du signal était modulée linéairement, ce qui correspond à un "chirp". De la même façon que pour la résolution en distance au sol  $\delta x$ , en réalisant un filtrage adapté du signal reçu, tout se passe comme si celui-ci n'était vu que sur une étendue  $\delta y = \frac{1}{B_a}$ , où  $B_a$  est la largeur de bande spatiale en azimuth. Comme  $B_a = K_a Y_a$  en notant  $Y_a$  la distance sur laquelle est vue une cible (donc  $Y_a = \beta_a R_o$ ), on obtient :

$$B_a = K_a \beta_a R_o = \frac{2}{\lambda R_o} \beta_a R_o = \frac{2\beta}{\lambda} = \frac{2}{L_a}$$

Finalement, nous obtenons  $\delta y = \frac{L_a}{2}$ . Pour ERS-1 (tab. 1.1), cela correspond à une résolution azimuthale de 5m.

En pratique pour parvenir à une résolution proche de cette borne inférieure, les processeurs ROS doivent tenir compte de nombreux phénomènes notamment les migrations des cibles au cours du déplacement du capteur [Curl-91].

La figure 1.5 récapitule des différentes étapes à réaliser avant l'obtention d'une image. Les corrections géométriques incluent notamment le rééchantillonnage des cellules de résolution pour obtenir des pixels carrés.

## 1.2.2 Déformations géométriques

Le processus même de formation des images radar entraîne plusieurs déformations géométriques [Jung-87] [Goui-91] qui sont dues à l'échantillonnage en distance. Celles-ci sont principalement liées à la présence de relief et plusieurs problèmes peuvent se rencontrer suivant la pente. D'une façon générale, on observe un raccourcissement des pentes orientées vers le capteur, qui apparaissent très brillantes sur l'image, et un allongement de celles qui lui sont opposées (fig.1.6a). Lorsque la pente est égale à l'angle d'incidence  $\theta$  les points situés le long de celle-ci ne peuvent plus être dissociés (fig.1.6b). Lorsqu'elle devient supérieure à  $\theta$ , les points sont imagés dans un ordre inverse à celui qu'ils ont au sol ; ce phénomène dit de repliement (lay-over ou fold-over) apparaît sous forme d'une torsade, zone claire suivie d'une zone sombre puis à nouveau d'une zone claire (fig.1.6c). Lorsque la pente du versant opposé au capteur a un angle supérieur à  $\frac{\pi}{2} - \theta$ , il y a interposition de l'élément de relief entre le sol et le capteur, d'où l'apparition de zones d'ombre dans l'image (fig.1.6d). Pour ERS-1, il s'agit de pentes supérieures à  $67^\circ$ , très rares en pratique.

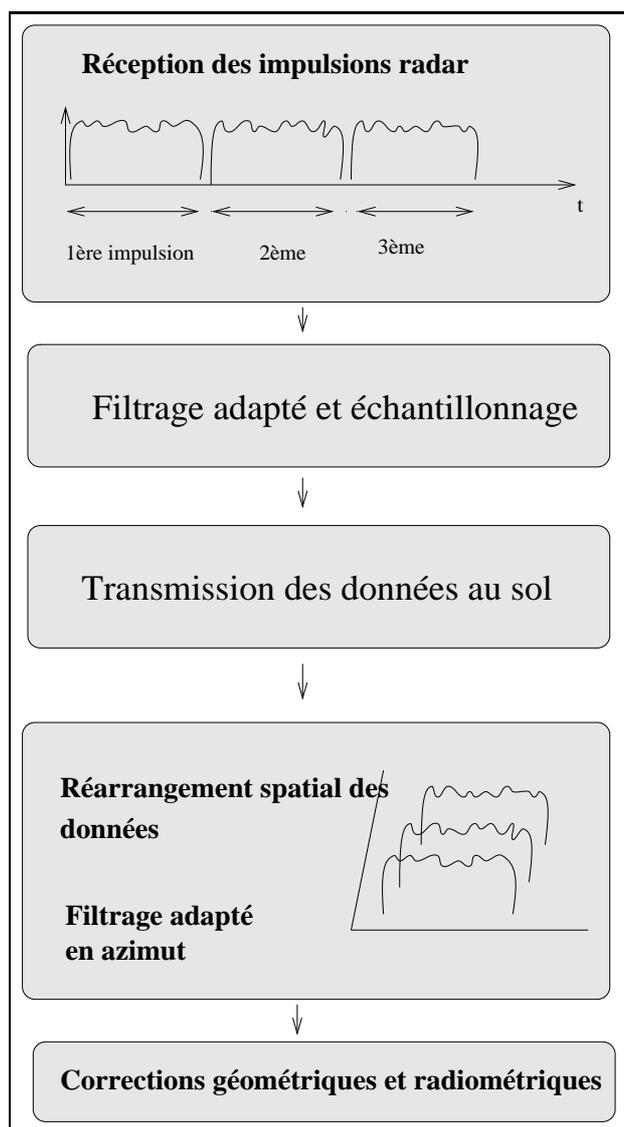


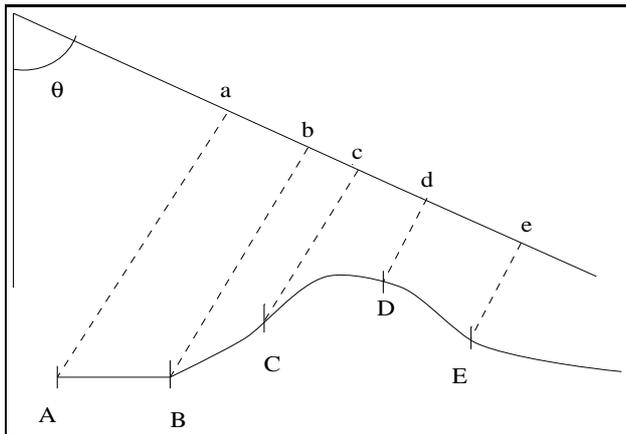
FIG. 1.5 – Les étapes de l'obtention des données

L'angle d'incidence du capteur est un facteur primordial dans ces déformations géométriques [GEOS-95]. Il conditionne non seulement le nombre de repliements, mais aussi celui des zones d'ombre. Lorsque  $\theta$  augmente, le premier diminue tandis que le second augmente ;  $\theta$  est donc choisi pour réaliser un compromis entre ces deux phénomènes.

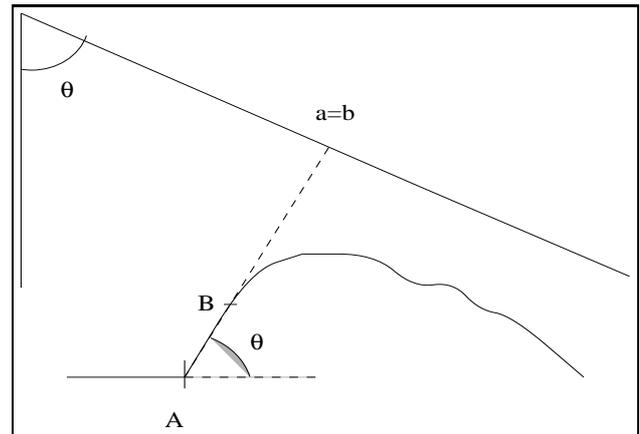
## 1.3 Statistiques des images ROS

### 1.3.1 L'équation radar

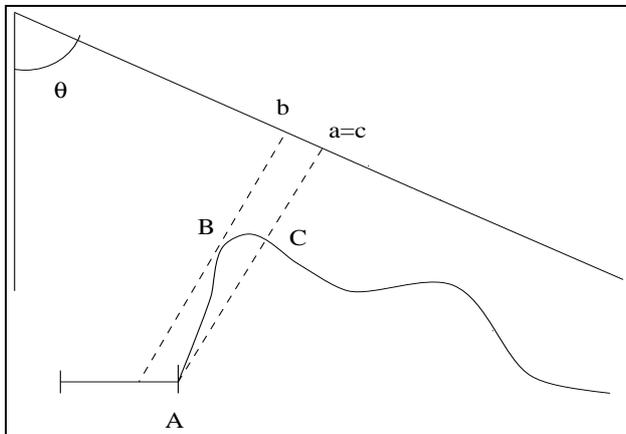
Nous allons d'abord détailler les phénomènes physiques qui interviennent dans la formation de l'image.



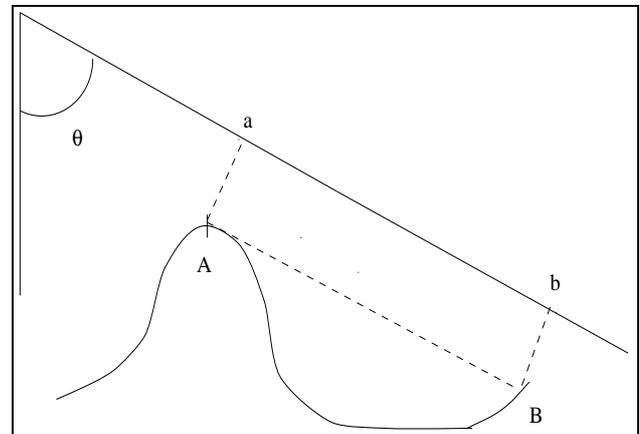
a. Présence de relief :  $AB = BC = DE$  mais  $bc < ab < de$



b. Ambiguïté entre points lorsque la pente est égale à  $\theta$ .



c. Phénomène de repliement (inversion des points imagés) pour une pente supérieure à  $\theta$



d. Phénomène de zone d'ombre (la partie AB n'est pas imagée)

FIG. 1.6 – Déformations géométriques dues au relief (les points  $a, b, c, \dots$  sont à distance radiale égale à celle de leurs homologues  $A, B, C, \dots$ , les arcs de cercle de rayon de courbure très élevés étant assimilés à des segments de droite)

L'intensité rayonnée par l'antenne d'émission à une distance  $R$  pour un point situé au centre de l'antenne est [Curl-91] :

$$I_t(R) = \frac{P_t G_t}{4\pi R^2}$$

où  $P_t$  est la puissance moyenne transmise par l'antenne et  $G_t$  le gain de l'antenne. Si nous nous plaçons dans le cas d'un radar mono-statique, l'intensité rétro-diffusée par une cible ponctuelle à la même distance  $R$  est :

$$I_r(R) = \frac{I_t(R)\sigma}{4\pi R^2} = \frac{P_t G_t \sigma}{(4\pi R^2)^2}$$

avec  $\sigma$  la section efficace (cross-section) de la cible qui est une valeur caractéristique de celle-ci.

La puissance rétro-diffusée finalement interceptée par l'antenne est :

$$P_r = I_r(R)A_e = \frac{P_t G_t \sigma A_e}{(4\pi R^2)^2}$$

avec  $A_e$  l'ouverture efficace de l'antenne. Cette expression représente l'équation radar. En prenant pour le bruit l'expression  $FkTB$  ( $B$  est la bande passante du signal émis) le rapport signal sur bruit qui s'en déduit est :

$$SNR = \frac{P_t G_t \sigma A_e}{(4\pi R^2)^2 FkTB}$$

Cette relation montre que si l'on augmente  $B$  pour améliorer la résolution, alors le rapport signal sur bruit diminue.

On voit que la puissance rétrodiffusée dépend de la nature de la cible par la valeur de sa surface efficace  $\sigma$ . Celle-ci dépend de nombreux paramètres parmi lesquels sa taille, son orientation, ses propriétés électro-magnétiques. En pratique, dans le cas des images satellitaires, ce sont surtout des cibles étendues qui sont rencontrées dans la nature. En supposant qu'une parcelle élémentaire  $dS$  du sol  $S$  peut être considérée comme une cible ponctuelle de surface efficace  $\sigma$ , on définit le coefficient de rétro-diffusion du sol  $\sigma^0$  par :

$$\sigma^0 = \left\langle \frac{\sigma}{dS} \right\rangle$$

où  $\langle X \rangle$  symbolise l'opération de moyennage sur  $X$ . Ce coefficient de rétro-diffusion varie suivant les directions d'émission et de réception et surtout est fonction de la rugosité de la cible par rapport à la longueur d'onde [Lope-90b]. Dans le cas d'une surface lisse par rapport à la longueur d'onde<sup>3</sup>, la réflexion suit une loi de Descartes (fig.1.7a), et toute l'intensité est rétro-diffusée dans la composante spéculaire (symétrique de la direction incidente par rapport à la normale); dans le cas monostatique, et si la normale n'est pas confondue avec la direction incidente, aucun signal n'est réfléchi vers le capteur et la surface apparaît alors noire sur l'image. Si elle est moyennement rugueuse, la rétrodiffusion n'a plus seulement lieu dans la direction spéculaire, mais également, bien que plus faiblement, dans d'autres directions (fig.1.7b). Dans le dernier cas, si elle est très rugueuse par rapport à  $\lambda$ , la surface est lambertienne et la rétro-diffusion a lieu uniformément dans toutes les directions (fig.1.7c).

### 1.3.2 Statistique du chatoiement totalement développé en 1-vue

L'onde électro-magnétique rétrodiffusée est reçue au niveau du capteur sous forme d'un signal complexe  $E$  de la forme  $ae^{j\phi}$ , ce signal étant représentatif de la surface au sol que le système imageur est capable de résoudre. A l'intérieur de cette cellule de résolution, dont la taille est grande par rapport à la longueur d'onde, se trouve un nombre fini  $N$  de

3. Le critère généralement adopté est que l'écart quadratique moyen des hauteurs de la surface doit être inférieur à  $\frac{\lambda}{8 \cos(\theta)}$  [Ulab-82].

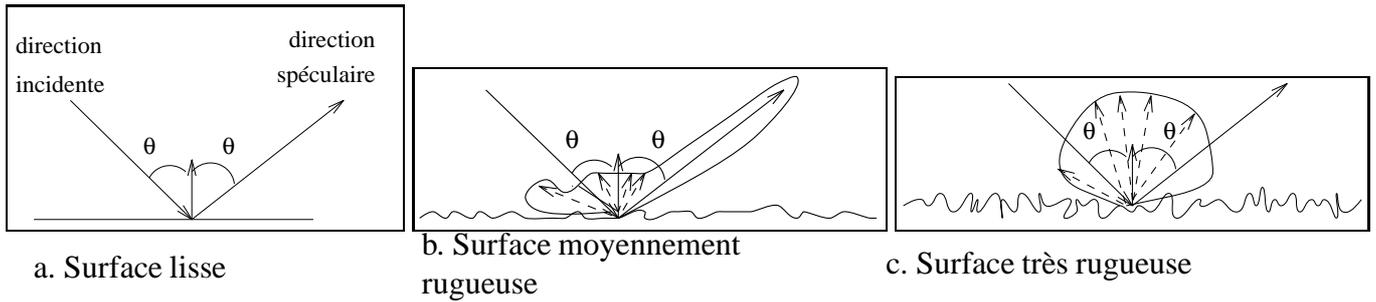


FIG. 1.7 – Diagrammes de diffusion en fonction de la rugosité de la surface par rapport à  $\lambda$

réflecteurs élémentaires, ayant chacun réfléchi l'onde électro-magnétique et dont les signaux s'additionnent de façon cohérente pour former le signal rétro-diffusé :

$$E = a e^{j\phi} = \sum_{i=1}^N a_i e^{j\phi_i} \quad (1.1)$$

En raison de l'interférence des ondes  $a_i e^{j\phi_i}$ , le signal résultant peut avoir une amplitude très différente selon les cas : grande quand les réflecteurs sont en phase, petite sinon. Le champ réfléchi peut donc être considéré comme une variable aléatoire, dépendant de la répartition des réflecteurs.

Ce phénomène inhérent à tous les systèmes d'imagerie cohérente a été beaucoup étudié. Il apparaît sur les images sous la forme d'un "bruit" important connu sous le nom de chatoiement ou "speckle", qui dégrade fortement la lisibilité des images. Ainsi des zones physiquement homogènes (champs, surfaces de mer calme...) possèdent une variabilité radiométrique très importante. Sous certaines hypothèses que nous détaillons dans la suite et regroupées sous le nom de "chatoiement totalement développé", le chatoiement des images peut être statistiquement parfaitement modélisé. C'est ce modèle proposé initialement par Goodman que nous développons maintenant [Good-75] [Good-76].

Reprenons l'équation 1.1, et supposons que les réflecteurs élémentaires aient les propriétés statistiques suivantes :

- ◇  $a_i$  et  $\phi_i$  sont indépendantes l'une de l'autre pour le réflecteur  $i$  ;
- ◇  $a_i$  et  $\phi_i$  sont indépendantes des amplitudes et phases des autres réflecteurs ;
- ◇ les phases  $\phi_i$  sont uniformément distribuées sur  $[-\pi; \pi]$ .

La dernière condition implique que la surface considérée soit rugueuse par rapport à  $\lambda$  pour qu'il y ait des excursions en phase de plusieurs fois  $2\pi$  permettant globalement une répartition uniforme des  $\phi_i$ . Par ailleurs, nous pouvons normaliser les amplitudes des réflecteurs élémentaires en remplaçant  $a_i$  par  $\frac{a_i}{\sqrt{N}}$  [Jake-87].

Commençons par étudier les statistiques des parties réelle  $\text{Re } E$  et imaginaire  $\text{Im } E$  de  $E$ . En utilisant les conditions évoquées précédemment, on montre que  $\text{Re } E$  et  $\text{Im } E$  ont des moyennes nulles, des variances égales à  $\frac{1}{N} \sum_{k=1}^N \frac{\langle |a_k|^2 \rangle}{2}$ , et qu'elles sont décorrélées.

Si nous nous plaçons maintenant dans le cas où  $N$  est grand, en appliquant le théorème

central limite<sup>4</sup>, nous pouvons déduire que  $\text{Re } E$  et  $\text{Im } E$  sont deux variables aléatoires gaussiennes indépendantes. On parle donc de chatoiement gaussien dans le cas de chatoiement totalement développé et sur une zone physiquement homogène. En notant  $f_x(t)$  la densité de probabilité (dpp) d'une variable aléatoire  $x$  pour la valeur  $t$  :

$$f_{(\text{Re } E, \text{Im } E)}(\text{Re } E, \text{Im } E) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{\text{Re } E^2 + \text{Im } E^2}{2\sigma^2}\right)$$

avec  $\sigma^2 = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N \frac{\langle |a_k^2| \rangle}{2}$ , et en notant  $\exp(x) = e^x$ .

On en déduit la densité conjointe de probabilité de l'intensité  $I = aa^* = \text{Re } E^2 + \text{Im } E^2$  et de la phase  $\phi$  :

$$\begin{aligned} f_{(I, \phi)}(I, \phi) &= \frac{1}{4\pi\sigma^2} e^{-\frac{I}{2\sigma^2}} \quad \text{si } I \geq 0 \quad \text{et } -\pi \leq \phi \leq \pi \\ &= 0 \quad \text{sinon} \end{aligned}$$

Finalement, la loi de la phase  $\phi$  est :

$$\begin{aligned} f_\phi(\phi) &= \int_0^{+\infty} p(I, \phi) dI \\ \text{donc } f_\phi(\phi) &= \frac{1}{2\pi} \quad \text{si } -\pi \leq \phi \leq \pi \\ &= 0 \quad \text{sinon} \end{aligned}$$

Ainsi dans les conditions du chatoiement totalement développé, la phase est distribuée uniformément sur  $[-\pi, \pi]$ .

Pour l'intensité, on obtient :

$$\begin{aligned} f_I(I) &= \int_{-\pi}^{+\pi} p(I, \phi) d\phi \\ \text{donc } f_I(I) &= \frac{1}{2\sigma^2} e^{-\frac{I}{2\sigma^2}} \quad \text{si } I \geq 0 \\ &= 0 \quad \text{sinon} \end{aligned}$$

Il s'agit d'une loi exponentielle négative. La moyenne de l'intensité  $2\sigma^2$  est proportionnelle au coefficient de rétro-diffusion  $\sigma^0$  de la surface imagée<sup>5</sup>. En notant  $\mu_x$  (ou  $\bar{x}$ ) la moyenne et  $\sigma_x$  l'écart-type d'une variable aléatoire  $X$ , on obtient pour l'intensité :

$$\mu_I = \sigma_I = 2\sigma^2$$

Cette égalité signifie que l'écart-type de l'intensité varie proportionnellement à sa moyenne, propriété qui donne le nom de bruit multiplicatif au chatoiement. Les zones claires d'une

4. Il n'est pas nécessaire que les  $a_i$  aient les mêmes statistiques; il suffit qu'elles soient indépendantes. Sous certaines conditions, on peut prévoir qu'elles auront les mêmes distributions [Jake-88].

5. En pratique, pour retrouver la valeur de ce paramètre (caractéristique de la surface) à partir de l'image, des problèmes d'étalonnage se posent [Touz-88a]. Cependant, c'est bien  $\sigma^0$  qui intervient pour toutes les modélisations de rétro-diffusion de surfaces (voir par exemple [Ulab-80] pour la végétation).

image auront donc une variabilité radiométrique bien plus importante que les zones sombres. Un paramètre généralement utilisé en imagerie radar pour caractériser l'homogénéité d'une zone est le coefficient de variation ou écart-type normalisé, qui est le rapport de l'écart-type sur la moyenne et que nous noterons  $\gamma_x = \frac{\sigma_x}{\mu_x}$ . Dans le cas d'une zone de chatoiement totalement développé, le coefficient de variation en intensité est égal à 1.

Pour le module  $A = \sqrt{I}$  de  $E$ , la loi est une loi de Rayleigh :

$$\begin{aligned} f_A(A) &= \frac{A}{\sigma^2} e^{-\frac{A^2}{2\sigma^2}} \quad \text{si } A \geq 0 \\ &= 0 \quad \text{sinon} \end{aligned}$$

La moyenne est  $\mu_A = \sqrt{\frac{\pi}{2}}\sigma$ , l'écart-type  $\sigma_A = \sqrt{2 - \frac{\pi}{2}}\sigma$  et le coefficient de variation :

$$\gamma_A = \frac{\sigma_A}{\mu_A} = \sqrt{\frac{4}{\pi} - 1} \approx 0.523 \quad (1.2)$$

### 1.3.3 Statistique du chatoiement totalement développé en L-vues

Le chatoiement entraîne une dégradation importante de la lisibilité des images. Pour réduire son effet, on utilise en imagerie radar la technique du multi-vues. Celle-ci consiste à additionner plusieurs images de la même zone de façon incohérente. En effet, si  $I_L = \frac{1}{L} \sum_{j=1}^L I_j$ , alors  $I_L$  suit une loi gamma (en notant  $\Gamma$  la fonction Gamma [Abra-72]) :

$$f_{I_L}(I) = \frac{L^L}{(2\sigma^2)^L \Gamma(L)} I^{(L-1)} e^{-\frac{LI}{2\sigma^2}} \quad (1.3)$$

de même moyenne que  $I$  ( $\mu_{I_L} = 2\sigma^2$ ), d'écart-type  $\sigma_{I_L} = \frac{2\sigma^2}{\sqrt{L}}$ , et donc de coefficient de variation  $\gamma_{I_L} = \frac{1}{\sqrt{L}}$ . Par conséquent, par rapport à l'image 1-vue en intensité, le coefficient de variation a été réduit d'un facteur  $\sqrt{L}$ .

Si nous étudions l'image en amplitude correspondante  $A_L = \sqrt{I_L}$ , nous obtenons une loi gamma généralisée [Laur-87] :

$$f_{A_L}(A) = \frac{2L^L}{(2\sigma^2)^L \Gamma(L)} A^{(2L-1)} e^{-\frac{LA^2}{2\sigma^2}} \quad (1.4)$$

La moyenne est de la forme :

$$\mu_{A_L} = \frac{\Gamma(L + 0,5)}{\sqrt{L}\Gamma^2(L)} \sqrt{2}\sigma$$

l'écart-type :

$$\sigma_{A_L} = \sqrt{1 - \frac{\Gamma^2(L + 0,5)}{L\Gamma^2(L)}} \sqrt{2}\sigma$$

et le coefficient de variation :

$$\gamma_{A_L} = \sqrt{\frac{L\Gamma^2(L)}{\Gamma^2(L+0,5)} - 1} \quad (1.5)$$

Une autre façon d'obtenir l'image en multi-vues serait de sommer les  $L$  images en amplitude  $\widetilde{A}_L = \frac{1}{L} \sum_{i=1}^L \sqrt{I_i}$ . Mais dans ce cas il n'existe pas d'expression analytique simple de la loi de  $\widetilde{A}_L$ . Par contre, on obtient  $\sigma_{\widetilde{A}_L} = \frac{\sigma_A}{\sqrt{L}}$ , ce qui donne au coefficient de variation une expression bien plus simple :

$$\gamma_{\widetilde{A}_L} = \frac{1}{\sqrt{L}} \frac{\sigma_A}{\mu_A} = \frac{1}{\sqrt{L}} \sqrt{\frac{4}{\pi} - 1} \approx \frac{0.523}{\sqrt{L}}$$

Dans la pratique nous approximerons  $\gamma_{A_L}$  par cette expression même lorsque l'image multi-vues en amplitude aura été obtenue à partir de l'image d'intensité. Le tableau Tab.1.2 montre quelques valeurs du coefficient de variation pour l'une et l'autre technique de multi-vues.

Nombre de vues	$\gamma_{\widetilde{A}_L} = \frac{1}{\sqrt{L}} \sqrt{\frac{4}{\pi} - 1}$	$\gamma_{A_L} = \sqrt{\frac{L\Gamma^2(L)}{\Gamma^2(L+0,5)} - 1}$
2	0.36300	0.36962
3	0.29410	0.30179
4	0.25362	0.26136
5	0.22624	0.23377
6	0.20615	0.21340

TAB. 1.2 – Coefficients de variation

En pratique, la technique du multi-vues est effectuée au niveau du processeur ROS en divisant la bande spectrale disponible en azimuth en  $L$  sous-bandes. Ainsi  $L$  images de résolution  $\delta y_L = L\delta y$  sont créées et les cellules de résolution de chacune de ces images sont vues avec un angle différent correspondant à chaque bande. La somme des intensités est effectuée de façon incohérente<sup>6</sup>. Une autre technique consisterait à effectuer sur l'image un moyennage spatial [Li-83].

A la place du nombre de vues est souvent utilisé le nombre de vues équivalent  $L_{eq}$  qui est le nombre de vues calculé empiriquement sur une zone homogène de l'image :

$$L_{eq} = \frac{1}{\gamma_{I_L}^2}$$

Cette valeur peut être légèrement inférieure au nombre de vues théorique, notamment lorsque les pixels sont corrélés. Dans le cas des images ERS-1, on obtient  $L_{eq} = 2,74$ , contre  $L = 3$  théoriquement.

6. si on obtenait  $L$  fois la même valeur de l'intensité, il n'y aurait bien sûr aucune réduction du speckle

### 1.3.4 Statistique du chatoiement non gaussien

Toutes les distributions qui ont été données au §1.3.3 sont valables uniquement dans le cas du speckle totalement développé et pour des zones homogènes (coefficient de rétro-diffusion constant), c'est à dire sans texture. Cela nécessite que les propriétés statistiques évoquées précédemment soient remplies, et que le nombre  $N$  de diffuseurs soit très grand.

Plusieurs démarches sont possibles pour améliorer ce modèle, soit en affaiblissant l'une ou l'autre des conditions sur lesquelles il repose, soit en proposant des modélisations différentes. Le chatoiement est alors encore totalement développé, mais une variation naturelle de la scène est prise en compte. Nous décrivons succinctement deux démarches possibles<sup>7</sup> qui toutes les deux conduisent à une distribution K de l'image radar.

- ◇ Jakeman [Jake-80] [Jake-87] ainsi que Jao [Jao-84] ont étudié l'influence du nombre de pas  $N$  dans le processus de marche aléatoire aboutissant à la construction de  $E$ , en le considérant comme une variable aléatoire suivant une distribution de Poisson conditionnellement à sa moyenne, i.e une loi binomiale négative si cette moyenne suit une loi gamma. Avec cette dernière hypothèse, en supposant que les  $a_j$  suivent des statistiques identiques et en faisant tendre  $N$  vers l'infini, on obtient une amplitude  $A$  suivant une loi  $K$  :

$$f_A(A) = \frac{2b}{\Gamma(\alpha)} \left(\frac{Ab}{2}\right)^\alpha K_{\alpha-1}(bA)$$

où le paramètre  $\alpha$  intervient dans la distribution de  $N$ , et  $b$  (avec  $\mu_a = \mu_{a_k}$ ) est défini par :

$$b = 2\sqrt{\frac{\alpha}{\mu_{a^2}}}$$

Dans [Jake-88], différentes distributions sont étudiées pour les  $a_j$  (avec  $N$  constant) ainsi que la distribution de  $A$  correspondante.

- ◇ Lewinsky [Lewi-83] reprend l'expression de la loi de l'intensité  $f_{I_L}$  (eq.1.3) en la considérant comme fonction du paramètre  $\mu_{I_L} = 2\sigma^2$ . Pour alléger les notations nous noterons  $I_L$  simplement  $I$ . Il considère donc que, en appliquant Bayès :

$$f_I(I) = \int f_I(I|\mu_I) f_{\mu_I}(\mu_I) d\mu_I$$

Il étudie ensuite plusieurs densités de probabilité pour  $\mu_I$  : loi uniforme, loi gamma, loi log-uniforme, log-normale. Dans le cas où  $\mu_I$  suit une loi gamma :

$$f_{\mu_I}(u) = \frac{m^m u^{m-1} e^{-\frac{mu}{\mu_I}}}{\Gamma(m) \mu_I^m}$$

avec  $m = \frac{1}{\gamma_{\mu_I}^2}$ , on retrouve pour  $I$  une loi K :

$$f_I(I) = \frac{2(Lm)^{\frac{L+m}{2}} I^{\frac{L+m-2}{2}}}{\Gamma(L)\Gamma(m)\mu_I^{\frac{L+m}{2}}} K_{m-L}\left(\sqrt{\frac{4LmI}{\mu_I}}\right)$$

7. Il s'agit de deux démarches complémentaires : l'une est principalement physique [Jake-80] [Jao-84], l'autre statistique [Lewi-83].

La distribution  $K$  est l'une des plus utilisées pour modéliser la rétrodiffusion dans l'image radar. Contrairement aux lois du chatoiement totalement développé, elle permet de tenir compte d'une variation de l'intensité moyenne, donc du coefficient de rétrodiffusion d'une surface, introduisant ainsi la notion de texture pour la scène imagée<sup>8</sup>. Le modèle le plus adapté pour des scènes naturelles semble être celui d'une loi gamma, comme l'attestent de nombreuses études sur des images ROS réelles [Jao-84], [Oliv-86], [Laur-87]. Jakeman [Jake-80] et Jao [Jao-84] proposent une explication fondée sur une analogie avec un processus de naissance, de mort et d'immigration du nombre de réflecteurs par cellule de résolution. C'est en effet le modèle statistique le plus simple conduisant à une densité de probabilité binomiale négative (les individus meurent et naissent dans des taux proportionnels à la population existante et leur nombre est augmenté par un taux d'immigration indépendant).

Une autre démarche pour étudier la distribution de l'image ROS en présence de texture est de faire une modélisation multiplicative de l'image, sous la forme  $I = RS$ , où  $R$  est la réflectivité de la scène et  $S$  le speckle "normalisé" [Ulab-86] [Laur-87].  $S$  suit alors une loi gamma de moyenne 1 :

$$f_S(S) = \frac{L^L}{\Gamma(L)} S^{L-1} e^{-LS}$$

Cette modélisation est strictement équivalente à celle de Lewinsky [Lewi-83] en prenant  $R = \mu_{I_L}$ , puisque la densité de probabilité d'un produit de variables aléatoires indépendantes<sup>9</sup> s'écrit [Kend-69] :

$$f_{RS}(I = RS) = \int f_R(R) f_S\left(\frac{I}{R}\right) \frac{1}{R} dR$$

En utilisant l'expression de  $f_S$ , on obtient :

$$f_S\left(\frac{I}{R}\right) \frac{1}{R} = \frac{1}{R} \frac{L^L}{\Gamma(L)} \frac{I^{L-1}}{R^{L-1}} e^{-\frac{LI}{R}}$$

et donc :

$$f_S\left(\frac{I}{R}\right) \frac{1}{R} = f_I(I|R)$$

On retrouve avec la modélisation multiplicative de l'intensité :

$$f_I(I) = \int f_R(R) f_I(I|R) dR$$

Le modèle multiplicatif est possible parce que  $f_I(I|R)$  peut s'écrire  $\frac{1}{R} f_S\left(\frac{I}{R}\right)$ . Le même raisonnement peut bien sûr être mené en amplitude.

8. Nous entendons par le mot texture un motif de scène venant se rajouter au speckle ; le chatoiement proprement dit, qui est présent sur une zone physiquement homogène, ne sera pas considéré comme une texture [Laur-87].

9. Cette formulation correspond en fait à une convolution de Mellin de  $f_R$  et  $f_S$ . Cette remarque permet d'utiliser les propriétés de la convolution de Mellin pour retrouver la loi suivie par l'intensité [Nico-97].

### 1.3.5 Statistique du chatoiement non totalement développé

Le cas de la présence dans la cellule de résolution d'un réflecteur déterministe en plus de ceux donnant lieu au chatoiement a aussi été largement étudié. Avec cette hypothèse la densité de probabilité de l'amplitude est une loi de Rice [Good-75] [Jake-87] [Goui-96b]. Le chatoiement n'est alors plus totalement développé.

### 1.3.6 Conclusion sur les statistiques du premier ordre

Si ces différentes modélisations ont l'intérêt de nous procurer des outils statistiques pour l'étude de détecteurs, il est néanmoins probable que la réalité dans l'image soit à mi-chemin entre ces différents cas. A l'exception de quelques surfaces, il s'agit souvent d'un mélange de texture et d'un ou plusieurs réflecteurs déterministes.

Il est par conséquent impossible de choisir un modèle statistique unique qui serait suivi sur toute l'image. Néanmoins, il est fréquent de supposer que l'image est simplement constituée de zones homogènes suivant une loi gamma en intensité ou gamma généralisée en amplitude.

### 1.3.7 Statistiques du deuxième ordre

Ces statistiques décrivent les relations entre un pixel et ses voisins. Elles sont indispensables pour modéliser des scènes texturées où l'organisation spatiale des pixels caractérise une région. La statistique du second ordre la plus utilisée est la fonction d'auto-corrélation définie (sous l'hypothèse de stationnarité) pour l'intensité  $I$  et pour  $L$  vues, par :

$$R_I(\Delta x, \Delta y, L) = \langle I(x, y), I(x + \Delta x, y + \Delta y) \rangle$$

Dans le cas d'une zone de chatoiement totalement développé (sans texture) et d'une réponse impulsionnelle idéale de type "fonction porte", elle s'écrit [Good-75] [Ulab-86] :

$$R_I(\Delta x, \Delta y, L = 1) = \mu_I^2 \left( 1 + \text{sinc}^2\left(\frac{\Delta x}{\delta x}\right) + \text{sinc}^2\left(\frac{\Delta y}{\delta y}\right) \right) \quad (1.6)$$

où  $\delta x$  et  $\delta y$  sont les résolutions en  $x$  et en  $y$  du capteur. Et pour  $L$ -vues :

$$R_I(\Delta x, \Delta y, L) = \frac{1}{N} (R_I(\Delta x, \Delta y, L = 1) + (N - 1))$$

Une expression peut également être obtenue pour la fonction d'auto-corrélation de l'amplitude [Ulab-86].

On peut déduire de l'équation 1.6, que si  $\Delta x > \delta x$  et  $\Delta y > \delta y$ , la corrélation entre pixels voisins est négligeable. Si l'espacement inter-pixel était supérieur aux résolutions  $\delta x$  et  $\delta y$ , les pixels ne seraient donc jamais corrélés. En pratique, l'espacement inter-pixel est souvent inférieur à la taille de la cellule de résolution (pour respecter le critère de Shannon<sup>10</sup>). Par

10. Celui-ci impose que si  $B$  est la bande passante du signal et  $f_e$  la fréquence d'échantillonnage, on doit respecter la contrainte suivante :  $f_e > 2B$

$\Delta y \setminus \Delta x$	0	1	2	3	4
0	1.	0.440540	-0.047847	-0.034347	0.006622
1	0.347007	0.161701	-0.005759	-0.007515	0.004670
2	0.004274	0.0005967	-0.009799	0.007608	0.004403
3	0.000633	-0.000894	0.004582	0.007507	0.008158
4	0.005126	0.002152	0.004057	0.004458	0.007224

TAB. 1.3 – Corrélation centrée normalisée  $\frac{\langle (I(x+\delta x, y+\Delta y) - \mu_I)(I(x, y) - \mu_I) \rangle}{\sigma_I^2}$  mesurée sur une zone homogène d'une image ERS-1 PRI

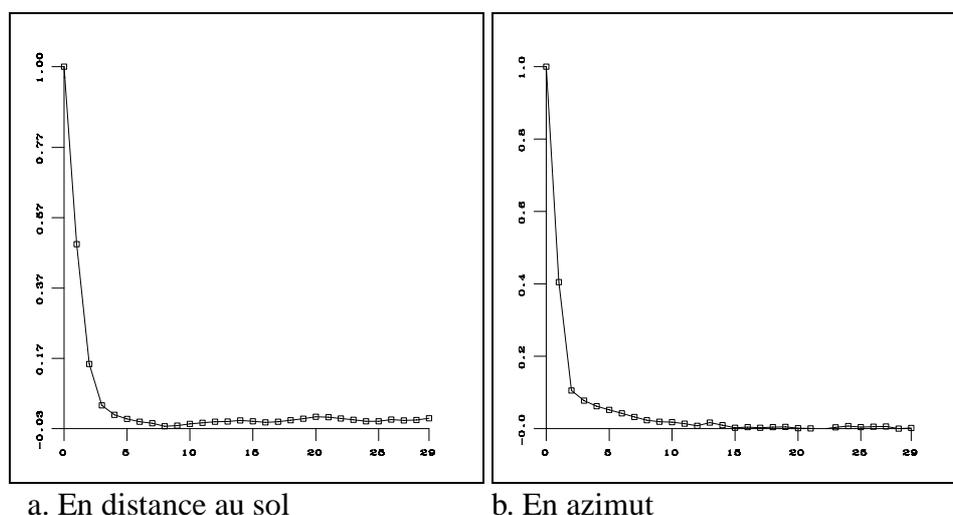


FIG. 1.8 – Corrélation expérimentale centrée normalisée en fonction de la distance (en pixels).

exemple, pour les images ERS-1 de précision (PRI), les résolutions sont de l'ordre de 25m en distance au sol et 18m en azimut à comparer avec un espacement inter-pixel de 12,5m. Cela signifie qu'un pixel est corrélé avec ses quatre plus proches voisins (Tab.1.3 et fig.1.8).

Bien sûr, outre la fonction d'auto-corrélation du chatoiement (qui est souvent négligée), il faut tenir compte d'une éventuelle auto-corrélation au niveau de la scène sous-jacente [Ulab-86]. Oliver a proposé plusieurs modèles de la fonction d'auto-corrélation du coefficient de rétro-diffusion pour l'interprétation et la simulation d'images radar [Oliv-84] [Oliv-86].

### 1.3.8 Format des images ERS-1

Les images ERS-1 sur lesquelles nous travaillons sont des images PRI (precision image). Il s'agit d'images en amplitude, en 3-vues et d'un espacement inter-pixel de 12,5m. Le multi-vues est réalisé par division de la bande spectrale en azimut. Ces images sont délivrées en 16 bits et les traitements qui seront proposés par la suite se feront sur ce format, sauf mention contraire [Goui-96]. La dynamique 16 bits est inégalement utilisée ; quelques

réflecteurs spéculaires, dont la normale est confondue avec la direction d'incidence, ont de très fortes réponses, le reste des valeurs radiométriques étant concentré pour la plupart des images naturelles entre 0 et  $\mu + 3\sigma$  (où  $\mu$  et  $\sigma$  sont la moyenne et l'écart-type de toute l'image en amplitude). La visualisation des images se faisant en 8 bits, nous ferons généralement la transformation suivante :

$$A_8 = 255 \quad \text{si } A_{16} > \mu + 3\sigma$$
$$A_8 = \frac{255}{\mu + 3\sigma} A_{16} \quad \text{sinon}$$

avec  $A_k$  l'amplitude de l'image stockée sur  $k$  bits.

Les images radar qui sont présentées dans ce rapport ont été visualisées après cette transformation.

Une description des principales images ERS-1 sur lesquelles seront illustrés les outils développés au cours de cette thèse se trouve en annexe (cf. Annexe A).

## 1.4 Conclusion

S'il rend difficile la lecture des images radar, le phénomène de chatoiement présente cependant l'intérêt d'être bien modélisé statistiquement. Nous avons vu que plusieurs modèles, et donc plusieurs distributions, plus ou moins complexes pouvaient être choisis. Nous utiliserons très souvent dans la suite les lois du chatoiement totalement développé sans texture (modèle gaussien). Car même simple puisqu'il suppose une région homogène, ce modèle tient compte de la spécificité de l'image radar. De plus, la complexité introduite par la prise en compte d'une texture est souvent inutile dans notre contexte (détection des éléments les plus structurants du paysage sur des images 3-vues), parce que biaisée par la présence de réflecteurs spéculaires.

Par ailleurs, nous avons vu que l'hypothèse d'indépendance des pixels n'était en toute rigueur pas vérifiée puisque la corrélation entre pixels voisins n'était négligeable qu'à partir de deux pixels de distance sur les images ERS-1.

## Chapitre 2

# Détecteurs de lignes en imagerie ROS

*Après une présentation non exhaustive des méthodes d'extraction de lignes existantes et de leur réponse aux images ROS, nous présentons deux détecteurs de structures linéaires capables de s'affranchir du chatoiement. Le premier détecteur, Dc1, est fondé sur des travaux précédemment effectués pour la détection de contours dans les images ROS [Touz-88a]. Nous rappelons les grandes lignes de ces travaux, avant d'en déduire un détecteur de lignes noté D1. Nous proposons ensuite un nouveau détecteur de contours Dc2. Celui-ci consiste à définir localement un modèle de contour, et à calculer le coefficient de corrélation entre ce modèle et le voisinage du pixel dont il est issu. Nous en déduisons un détecteur de structures linéaires D2. Ces deux détecteurs de lignes sont étudiés théoriquement de façon statistique, et pratiquement à l'aide de zones de l'image sur lesquelles leurs performances sont évaluées et comparées. Finalement, nous proposons un détecteur constitué par la fusion des réponses à D1 et D2, qui est également étudié.*

*Le résultat de cette détection de lignes, sous forme de segments, servira de point de départ à une étape de plus haut niveau qui réalise l'opération de fermeture des structures linéaires, et qui fera l'objet du chapitre 3. Des applications (détection du réseau routier, hydrographique et de la présence de relief) seront ensuite présentées au chapitre 4.*

### 2.1 Présentation du problème

L'extraction des lignes dans les images aériennes ou satellitaires (étape souvent préalable à la détection des réseaux routiers, ferrés ou fluviaux) est un problème difficile, même dans le domaine optique réputé plus facile, et il a donné lieu à de nombreuses publications. Nous nous intéressons ici aux méthodes locales, travaillant sur un voisinage d'une dizaine ou de quelques dizaines de pixels autour d'un pixel pour lui associer une mesure d'appartenance à une structure linéaire. Les détecteurs qui ont été proposés sont nombreux et souvent dédiés à une application et à une résolution particulière. Les résultats sont presque toujours incomplets et bruités, et nécessitent ensuite une phase globale de fermeture dont nous parlerons au chapitre 3. Nous présentons ici quelques détecteurs de lignes.

Une première technique de détection consiste à utiliser des détecteurs de contours, puis à appliquer des post-traitements adaptés. Il s'agit donc souvent de réaliser un filtrage li-

néaire bidimensionnel, généralement sous forme de convolution de l'image avec un jeu de masques. C'est la méthode utilisée par exemple par Nevatia [Neva-80], qui définit un détecteur de contours composé d'un ensemble de six masques correspondant à des contours idéaux. Graffigne [Graf-89] utilise le détecteur de Canny-Deriche [Cann-86] [Deri-87]. Cependant, l'utilisation directe des détecteurs de contours n'est possible que lorsqu'il s'agit de la détection de lignes suffisamment épaisses. En effet, il faut que les deux bords de la structure soient au moins distants d'une demi-largeur du masque. La détection des lignes proprement dites demande ensuite une étape de mise en correspondance des contours parallèles.

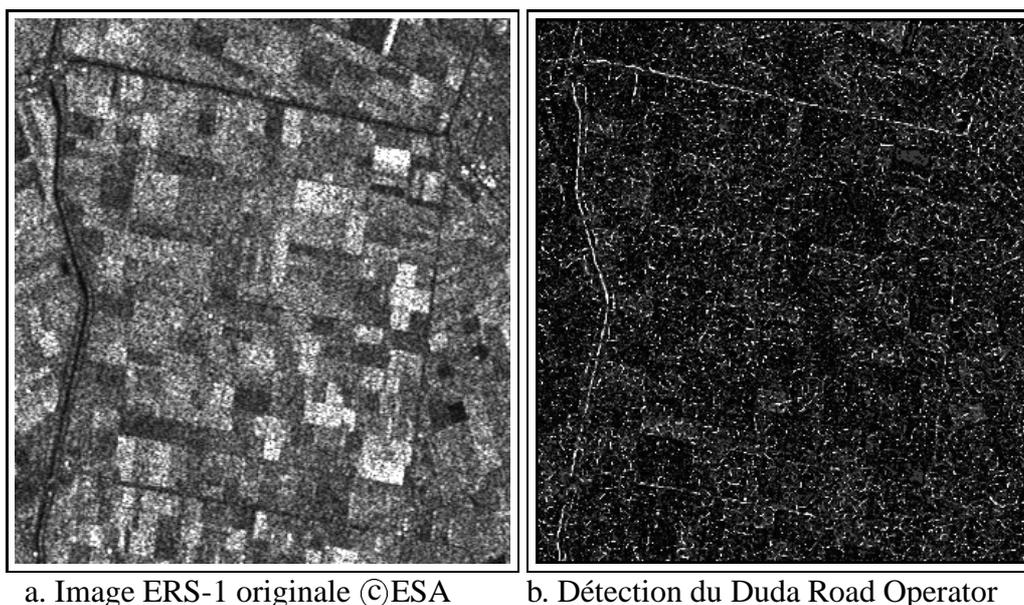
Bien souvent, des détecteurs directement dédiés à la recherche des structures linéaires sont utilisés. Citons par exemple :

- Le détecteur semi-linéaire de VanderBrug [Vand-76]. Il est constitué d'un ensemble de quatorze masques, chaque masque étant formé de trois triplets de pixels ou de blocs de  $2 \times 2$  pixels. La réponse au masque est calculée par une différence entre les moyennes des zones. Sa réponse reste très bruitée malgré les améliorations apportées [Vand-77].
- Le Duda Road Operator (DRO). Cet opérateur mesure l'uniformité de la radiométrie le long de la route supposée, combinée à une mesure de contraste entre cette route et les zones adjacentes. Il est souvent utilisé pour la détection du réseau routier en imagerie SPOT [Fisc-81] [Roux-92].
- Jédynack propose également un détecteur de structures [Jedy-91] [Jedy-95]. Il utilise le fait que la variation des niveaux de gris le long de la route doit être inférieure en valeur absolue à la variation des niveaux de gris dans la direction orthogonale et des deux côtés. Un score est calculé en extrayant un certain nombre de paires de pixels, et en combinant leurs différences radiométriques.

La morphologie mathématique apporte également une réponse à la détection des crêtes (et donc des vallées) d'intensité lumineuse d'une image avec le "chapeau haut de forme". Celui-ci, qui consiste à soustraire à une image son ouverture, est souvent utilisé pour la détection du réseau routier [Bert-88].

A de plus hautes résolutions, notamment sur les images aériennes, les réseaux sont suffisamment larges pour être considérés comme des régions de l'image ; d'autres techniques sont alors mises en œuvre : Airault [Aira-94] utilise l'information de texture et les routes sont détectées au niveau local comme étant particulièrement homogènes ; Mc Keown [McKeo-88] utilise la corrélation croisée entre un profil de route extrait de l'image dans la direction perpendiculaire à la route cherchée, et un modèle de profil défini une fois pour toutes à l'aide de connaissances à priori.

Il n'est pas question ici de comparer ces différentes techniques, qui sont bien souvent développées pour un type d'image spécifique et à une résolution particulière. Nous voulons simplement souligner que tous ces détecteurs, qui supposent un bruit blanc gaussien additif lorsque le bruit est modélisé, ne sont pas adaptés au problème du chatoiement. La figure 2.1 montre la réponse du Duda Road Operator sur une image ROS, détecteur pourtant particulièrement efficace sur des images SPOT. Les autres détecteurs testés ont également donné des résultats très bruités et inexploitable, conformément à des conclusions antérieures [Burn-81] [Giess-84] [Kwok-89] [Adai-90].



a. Image ERS-1 originale ©ESA

b. Détection du Duda Road Operator

FIG. 2.1 – Exemple de détection

En réalité, il était prévisible que tous ces détecteurs seraient mis en échec sur des images radar. En effet, ils sont dans leur grande majorité fondés sur des différences de moyennes entre zones. Citons-en quelques uns : la convolution par un ensemble de masques modélisant le contour (-template matching- dont les opérateurs Sobel, Prewitt, ou Kirsch) ; les opérateurs basés sur le gradient ou les passages par zéro du Laplacien après filtrage par une gaussienne de différentes tailles ; la décomposition du détecteur de contours 2D en une détection 1D, et une opération de continuation 1D. Tous ces détecteurs se ramènent à une différence de moyennes pondérées ou non (modèle DOA, Difference Of Average) [Lacr-88]. C'est le cas également pour presque tous les détecteurs de lignes cités précédemment. Or, ces opérateurs DOA ont sur les images ROS le défaut majeur d'avoir un comportement différent suivant la radiométrie moyenne de la zone. Touzi a montré de façon théorique et vérifié expérimentalement, que le taux de fausse alarme de ces opérateurs augmente avec la radiométrie moyenne de la zone sur des images soumises au chatoiement [Touz-88a]<sup>1</sup>.

## 2.2 Le détecteur de contours Dc1

Une solution pour s'affranchir de ce problème lié à l'imagerie radar consiste à considérer non plus la différence des valeurs radiométriques, mais leur rapport [Bovi-88]. Ainsi en imagerie ROS, l'usage du rapport entre radiométries moyennes de deux zones est l'équivalent du gradient généralisé en imagerie optique.

Partant de ce principe, Touzi, Lopes et Bousquet ont mis au point un détecteur de contours à probabilité de fausse alarme constante pour un seuil de décision donné [Touz-88b]. Le taux de détection pour un rapport de contraste  $c$  fixé est constant, quelle que soit la ra-

1. Ceci est lié au comportement multiplicatif du chatoiement qui fait que l'écart-type augmente avec la radiométrie moyenne d'une zone §1.3.1.

diométrie moyenne. Par ailleurs, ces auteurs ont montré que les seuils de décision peuvent être déduits du nombre de vues  $L$ , de la taille de la fenêtre utilisée pour le traitement et de la probabilité de détection pour un rapport de contraste  $c$  fixé.

### 2.2.1 Définition de Dc1

Nous reprenons rapidement ici la définition et l'étude qui ont été faites du détecteur par Touzi, en admettant en plus des tailles de zones différentes. Les densités de probabilités introduites nous serviront pour l'étude du détecteur de structures linéaires. Nous notons ce détecteur Dc1.

Dans toute la suite nous notons  $f_x(t|p_1, \dots, p_k)$  la densité de probabilité (ddp) d'une variable aléatoire  $x$  pour la valeur  $t$  et les valeurs des paramètres  $p_1, \dots, p_k$ . La fonction de répartition est notée  $\Phi_x(t|p_1, \dots, p_k)$ . Pour simplifier les notations, l'indice  $L$  du multi-vues est abandonné.

Considérons une image L-vues en amplitude et une zone d'intensité moyenne  $P$  ( $P = 2\sigma^2$  est proportionnelle au coefficient de rétrodiffusion  $\sigma^0$  de la cible eq.1.3). En supposant qu'il s'agit d'une zone de chatoiement totalement développé, la densité de probabilité de l'amplitude suit une loi gamma généralisée (§1.3.2) :

$$f_A(x|P) = \frac{2L^L}{P^L \Gamma(L)} x^{(2L-1)} e^{-\frac{Lx^2}{P}}$$

En notant  $A_s$  l'amplitude en un site  $s$ , la moyenne radiométrique empirique d'une région  $i$  constituée de  $n_i$  pixels est :

$$\bar{A}_i = \frac{1}{n_i} \sum_{s \in \mathcal{R}e_i} A_s$$

avec  $\mathcal{R}e_i$ , l'ensemble des indices des pixels de la région  $i$ . En supposant les  $n_i$  pixels indépendants et en notant  $P_i$  l'intensité moyenne de la région  $i$ , on a la densité de probabilité<sup>2</sup> :

$$f_{\bar{A}_i}(t|P_i) = \frac{2n_i L^{n_i L}}{P_i^{n_i L} \Gamma(n_i L)} t^{(2n_i L-1)} e^{-\frac{n_i L t^2}{P_i}} \quad (2.1)$$

Dans le cas d'un détecteur de contour placé au pixel  $x_0$ , pour une direction présumée du contour  $\vec{d}_k$ ,  $k \in \{0, \dots, \mathcal{N}_d\}$  où  $\mathcal{N}_d$  est le nombre total de directions (fig.2.2a), les moyennes sont calculées de part et d'autre d'un axe centré en  $x_0$  de direction  $\vec{d}_k$ .

On forme alors le rapport  $r_{ij}^{\sim}$  des deux moyennes  $\bar{A}_i$  et  $\bar{A}_j$  ( $r_{ij}^{\sim}$  dépend de  $x_0$  et de  $\vec{d}_k$ ) :

$$r_{ij}^{\sim} = \frac{\bar{A}_i}{\bar{A}_j}$$

Ce détecteur prend ses valeurs entre 0 et  $+\infty$ , on lui préférera le détecteur  $r_{ij}^*$  qui prend ses valeurs entre 0 et 1 [Touz-88a] :

$$r_{ij}^* = \min\left(\frac{\bar{A}_i}{\bar{A}_j}, \frac{\bar{A}_j}{\bar{A}_i}\right)$$

2. Le moyennage spatial de  $n_i$  pixels indépendants revient à faire du  $n_i L$ -vues.

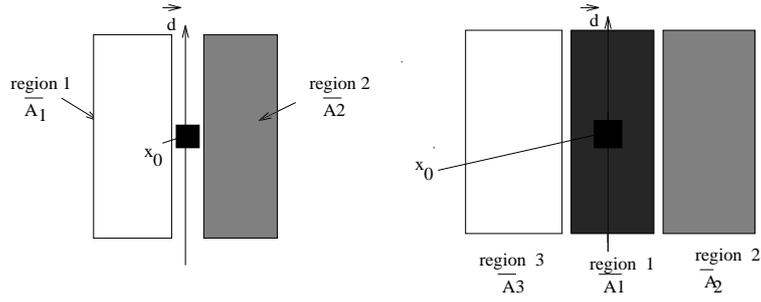


FIG. 2.2 – Forme des détecteurs de contours et de structures

Exprimons la densité de probabilité de  $r_{ij}^*$ . Pour cela explicitons d'abord celle de  $r_{ij}^{\sim}$  [Kend-69] :

$$f_{r_{ij}^{\sim}}(t|P_i, P_j) = \int_0^\infty f_{A_i}(tx) f_{A_j}(x) x dx$$

En remplaçant par eq.2.1, on obtient :

$$f_{r_{ij}^{\sim}}(t|P_i, P_j) = \frac{4}{\Gamma(n_i L)\Gamma(n_j L)} \left(\frac{n_i}{P_i}\right)^{n_i L} \left(\frac{n_j}{P_j}\right)^{n_j L} t^{2n_i L-1} h(t|P_i, P_j)$$

$$\text{où } h(t|P_i, P_j) = \int_0^\infty x^{2L(n_i+n_j)-1} e^{-x^2(t^2 \frac{n_i L}{P_i} + \frac{n_j L}{P_j})} dx$$

En effectuant alors le changement de variable  $u = x^2(t^2 \frac{n_i L}{P_i} + \frac{n_j L}{P_j})$ , et après calcul en utilisant la définition de la fonction Gamma, on a :

$$f_{r_{ij}^{\sim}}(t|P_i, P_j) = \frac{2\Gamma(n_i L + n_j L)}{\Gamma(n_i L)\Gamma(n_j L)} \left(\frac{n_i}{P_i}\right)^{n_i L} \left(\frac{n_j}{P_j}\right)^{n_j L} \frac{t^{2n_i L-1}}{(t^2 \frac{n_i}{P_i} + \frac{n_j}{P_j})^{L(n_i+n_j)}}$$

On peut exprimer ce terme en fonction du contraste  $c_{ij} = \frac{\sqrt{P_i}}{\sqrt{P_j}}$  entre les zones  $i$  et  $j$ <sup>3</sup> ; le résultat ne dépend alors plus que de  $c_{ij}$ , et donc la probabilité de détection est toujours la même pour un contraste fixé, quelles que soient les radiométries des régions.

$$f_{r_{ij}^{\sim}}(t|c_{ij}) = \frac{2\Gamma(n_i L + n_j L)}{\Gamma(n_i L)\Gamma(n_j L)} n_i^{n_i L} n_j^{n_j L} \frac{t^{2n_i L-1}}{(t^2 n_i + n_j c_{ij}^2)^{L(n_i+n_j)}} c_{ij}^{2n_j L}$$

Puisque pour la variable aléatoire  $\min(x, y)$  la ddp est :

$$f_{\min(x,y)}(t) = f_x(t)\Phi_y(t) + f_y(t)\Phi_x(t) \quad (2.2)$$

$f_{r_{ij}^*}$  est finalement obtenue :

$$f_{r_{ij}^*}(t|c_{ij}) = \frac{2\Gamma(n_i L + n_j L)}{\Gamma(n_i L)\Gamma(n_j L)} n_i^{n_i L} n_j^{n_j L} \left[ \frac{c_{ij}^{2n_j L} t^{2n_i L-1}}{(t^2 n_i + n_j c_{ij}^2)^{L(n_i+n_j)}} + \frac{(\frac{1}{c_{ij}^2})^{n_i L} t^{2n_j L-1}}{(t^2 n_j + \frac{n_i}{c_{ij}^2})^{L(n_i+n_j)}} \right]$$

3. Nous avons choisi de définir  $c$  ainsi pour qu'il soit proportionnel au rapport des amplitudes.

Plutôt que  $r_{ij}^*$  qui tend vers 0 en présence d'un contour de fort contraste et vers 1 sur une zone homogène, nous préférons définir  $r_{ij} = 1 - r_{ij}^*$ . Nous avons alors  $f_{r_{ij}}(t|c_{ij}) = f_{r_{ij}^*}(1-t|c_{ij})$ , et  $\Phi_{r_{ij}}(t|c_{ij}) = 1 - \Phi_{r_{ij}^*}(t|c_{ij})$ .

La densité de probabilité de  $r_{ij}$  ne dépend que du contraste  $c_{ij}$  entre les deux régions, et donc la probabilité de détection est constante pour un contraste donné. Un contour sera détecté pour un seuil de décision  $r_{min}$  donné lorsque  $r_{ij} > r_{min}$ .

## 2.2.2 Probabilités de détection et de fausse alarme de Dc1

La probabilité de détection s'obtient pour un seuil  $r_{min}$  donné par :

$$P_d(r_{min}, c_{ij}) = \int_{r_{min}}^1 f_{r_{ij}}(t|c_{ij}) dt$$

De même, on peut définir la probabilité de fausse alarme du détecteur par :

$$P_\phi(r_{min}) = P_d(r_{min}, c_{ij} = 1)$$

C'est la probabilité de détecter un contour sur une zone homogène (i.e  $P_i = P_j$ ).

## 2.3 Le détecteur de lignes D1

Nous proposons et étudions dans cette partie un détecteur de lignes déduit de Dc1. Contrairement à Nezry [Nezr-92] qui suppose un "fond" homogène et effectue parallèlement une détection de contours, nous proposons une formulation générale rendant possible l'existence de différences radiométriques entre les bords droit et gauche de la structure linéaire.

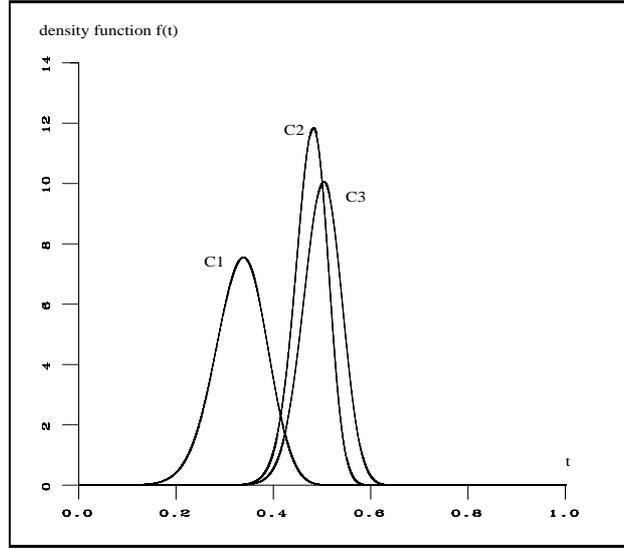
### 2.3.1 Définition de D1

Nous définissons le détecteur de structures linéaires  $r$  par (fig.2.2) :

$$r = \min(r_{12}, r_{23})$$

où  $r_{ij}$  est la réponse du détecteur de contour entre les zones  $i$  et  $j$ . Les moyennes sont calculées comme indiqué sur la figure 2.2, le long de la structure linéaire et sur les deux zones adjacentes. Pour une direction donnée, le détecteur proposé revient à faire une détection de contours de part et d'autre de la ligne et à conserver la moins bonne réponse. Cette contrainte stricte nous assure que seules les lignes (et non les contours) seront détectées. Une solution plus tolérante serait de combiner les deux réponses.

Ici encore, cette formulation correspond à une seule direction ; en pratique  $\mathcal{N}_d$  directions sont testées. De plus, suivant l'application considérée (voir le chapitre 4), des lignes plus ou moins épaisses doivent être détectées. Ainsi plusieurs largeurs pour la région centrale sont essayées, et donc autant de réponses calculées.



Densités de probabilité pour différents contrastes :  $C_1$  pour  $c_{12} = 2$ ,  $c_{13} = 1,5$  ;  $C_2$  pour  $c_{12} = c_{13} = 2$  ;  $C_3$  pour  $c_{12} = 2$ ,  $c_{13} = 4$  (avec  $L = 3$ ,  $n_1 = 33$ ,  $n_2 = n_3 = 22$ , i.e un masque de longueur 11 pixels, de largeur 7, et une zone centrale d'épaisseur 3).

FIG. 2.3 – Densités de probabilité de  $DI$ .

Envisageons tout d'abord le cas d'une direction  $\vec{d}_k$ ,  $k \in \{0, \dots, \mathcal{N}_d\}$  fixée. De la partie précédente et en utilisant l'équation 2.2, nous déduisons la densité de probabilité de  $r$  :

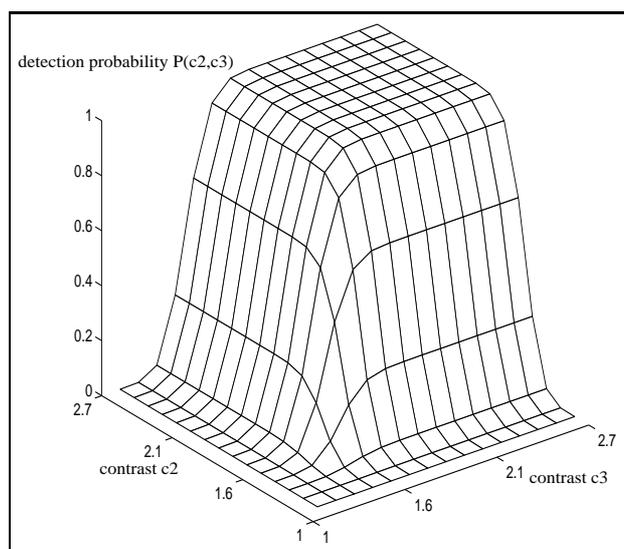
$$f_r(t|c_{12}, c_{13}) = f_{r_{12}}(t|c_{12})\Phi_{r_{13}}(t|c_{13}) + f_{r_{13}}(t|c_{13})\Phi_{r_{12}}(t|c_{12})$$

ou encore :

$$f_r(t|c_{12}, c_{13}) = \frac{4\Gamma((n_1 + n_2)L)\Gamma((n_1 + n_3)L)}{\Gamma(n_1L)^2\Gamma(n_2L)\Gamma(n_3L)} n_1^{2n_1L} n_2^{n_2L} n_3^{n_3L} \times (g(t|c_{12}) \int_t^1 g(x|c_{13}) dx + g(t|c_{13}) \int_t^1 g(x|c_{12}) dx) \quad (2.3)$$

$$\text{où } g(x|c_{1i}) = \frac{c_{1i}^{2n_iL}(1-x)^{2n_iL-1}}{((1-x)^{2n_i} + n_i c_{1i}^2)^{L(n_i+n_i)}} + \frac{\left(\frac{1}{c_{1i}^2}\right)^{n_iL}(1-x)^{2n_iL-1}}{\left((1-x)^{2n_i} + \frac{n_i}{c_{1i}^2}\right)^{L(n_i+n_i)}} \quad (2.4)$$

Comme cette expression ne dépend que des contrastes  $c_{12}$  et  $c_{13}$  entre la zone centrale et les deux zones adjacentes, ce détecteur a une probabilité de fausse alarme constante pour des contrastes donnés. Des exemples de  $f_r(t|c_{12}, c_{13})$  sont présentés fig.2.3 pour différents couples  $(c_{12}, c_{13})$ . La réponse du détecteur varie de 0 pour des contrastes nuls, à 1 pour des contrastes infinis. Les courbes  $C_2$  et  $C_3$  obtenues pour la même valeur de  $c_{13}$  montrent dans quelle mesure les deux bords s'influencent.



Probabilité de détection en fonction des contrastes  $c_{12}$  et  $c_{13}$  de part et d'autre de la ligne pour un seuil  $r_{min} = 0.3$  et des fenêtres de tailles  $n_1 = 33$ ,  $n_2 = n_3 = 22$

FIG. 2.4 – Probabilité de détection de D1 en fonction des contrastes.

### 2.3.2 Probabilités de détection et de fausse alarme de D1

La probabilité de détection s'obtient pour un seuil  $r_{min}$  donné par :

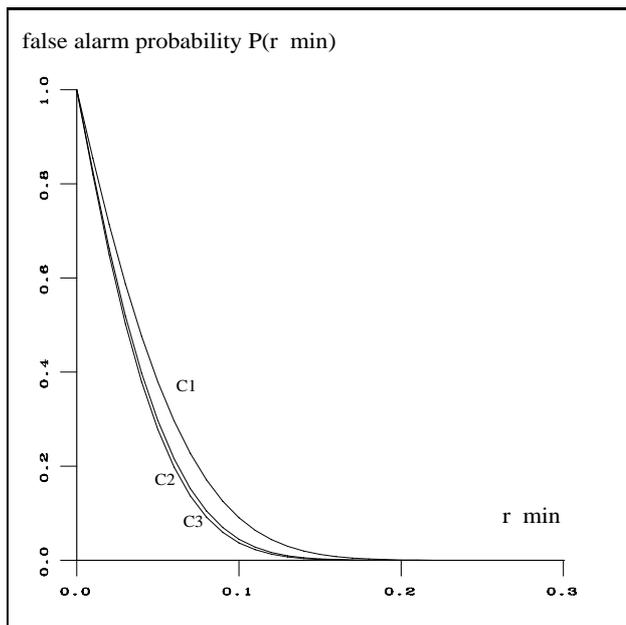
$$P_d(r_{min}, c_{12}, c_{13}) = \int_{r_{min}}^1 f_r(t|c_{12}, c_{13}) dt$$

La surface de la figure 2.4 montre la probabilité de détection pour un seuil  $r_{min}$  donné en fonction des contrastes  $c_{12}$  et  $c_{13}$ . On s'aperçoit que pour avoir une probabilité de détection de 90%, il faut un contraste suffisant de part et d'autre de la structure linéaire (pratiquement d'au moins 2dB en amplitude soit 4dB en puissance).

Parallèlement, étudions la probabilité de fausse alarme du détecteur. Deux cas peuvent se présenter : la détection d'une structure linéaire sur une zone homogène ( $c_{12} = c_{13} = 1$ ), ou à la place d'un contour unique ( $c_{12} = 1$  et  $c_{13} = c$ , ou  $c_{12} = c$  et  $c_{13} = 1$ ). Dans ces deux cas nous pouvons écrire :

$$P_\phi(r_{min}, c) = P_d(r_{min}, 1, c) = P_d(r_{min}, c, 1) = \int_{r_{min}}^1 f_r(t|1, c) dt$$

Les deux figures 2.5a et 2.5b, représentent ces probabilités. On constate que l'influence de la taille des zones est tout à fait minime pour des fenêtres suffisamment larges (fig.2.5a). Sur la figure 2.5b, on constate que la probabilité de détecter une structure linéaire sur une zone homogène est très faible pour un seuil supérieur à 0,2. Par ailleurs, si la probabilité de fausse alarme dans le cas d'un contour est toujours supérieure à celle sur une zone homogène, elle ne dépend plus néanmoins du contraste de ce contour au-delà d'un certain seuil (les courbes pour des contours de contraste 2 et 4 sont confondues).

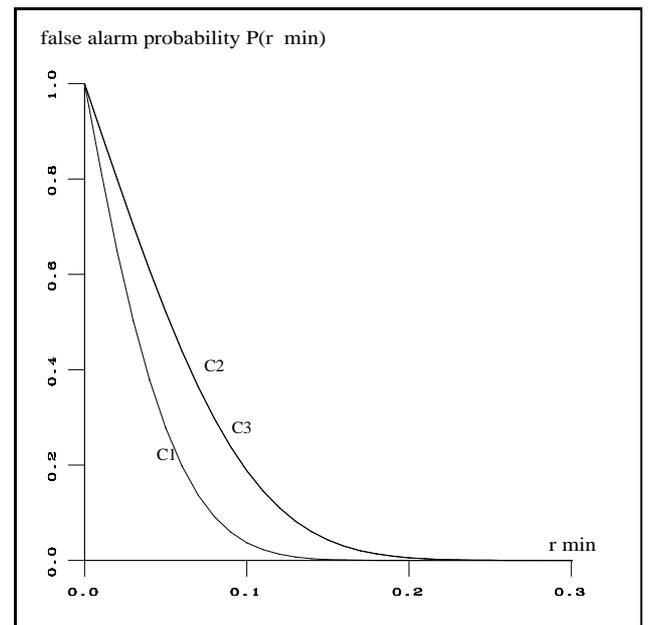


a. Influence du nombre de pixels sur  $P_\phi(r_{min}, 1)$  zone homogène ;

$C_1 : n_1 = 11, n_2 = n_3 = 33$  ;

$C_2 : n_1 = n_2 = 22, n_3 = 33$  ;

$C_3 : n_1 = 33, n_2 = n_3 = 22$ .



b. Influence du contraste  $c$  du contour sur  $P_\phi(r_{min}, c)$  ;

$C_1 : c = 1$  ;

$C_2 : c = 2$  ;

$C_3 : c = 4$ .

FIG. 2.5 – Probabilités de fausse alarme de D1  $P_\phi(r_{min}, c)$  en fonction du seuil de décision  $r_{min}$  pour différents jeux de paramètres.

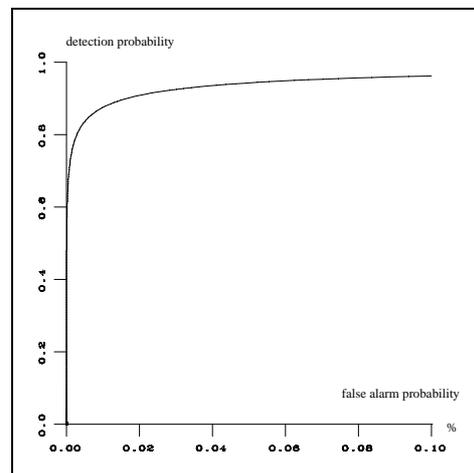


FIG. 2.6 – Probabilité de détection ( $c_{12} = 2$  et  $c_{13} = 1, 5$ ) en fonction de la probabilité de fausse alarme en % (contour avec  $c = 2$ ).

D'une façon générale, comme toujours lorsque le seuil de décision diminue, la probabilité de détection et celle de fausse alarme augmentent (fig.2.6). Ainsi le seuil de décision  $r_{min}$  doit être choisi de façon à réaliser un compromis entre ces deux contraintes antagonistes.

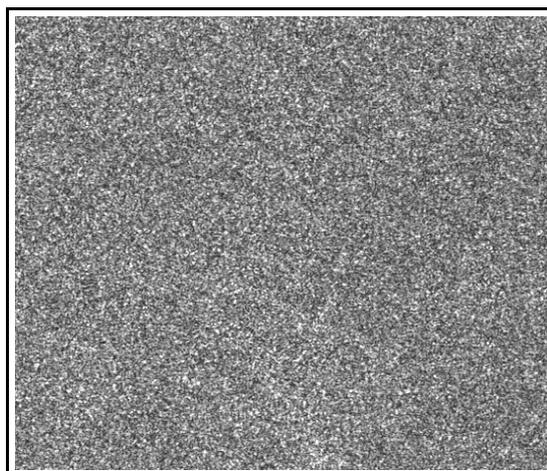
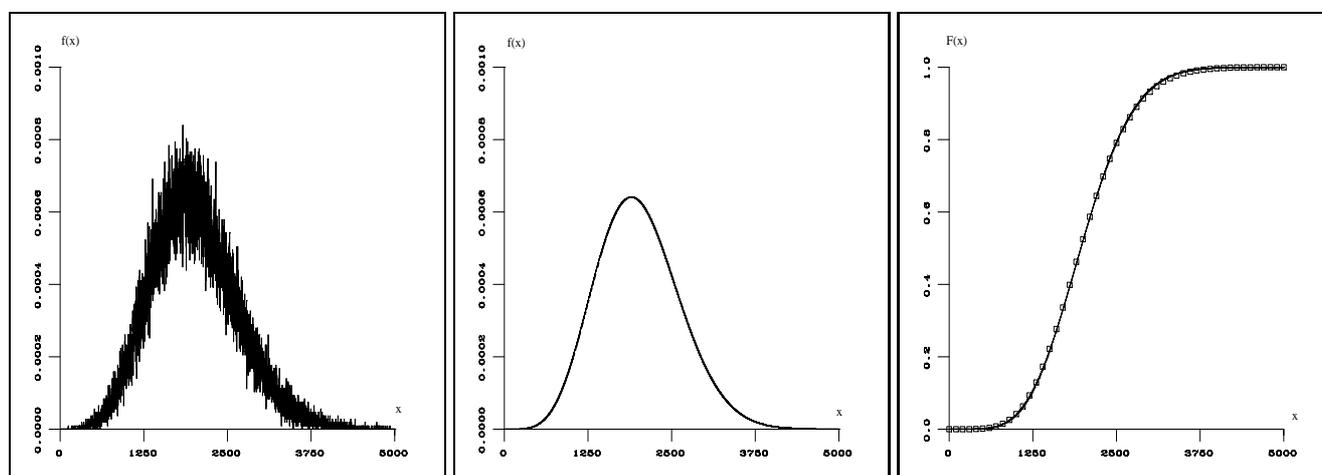


FIG. 2.7 – Zone-test de speckle totalement développé (ERS-1 ©ESA,  $256 \times 256$  pixels).

### 2.3.3 Validation empirique sur une zone-test pour D1

Si les études théoriques nous donnent une bonne compréhension du comportement du détecteur, il nous faut cependant voir dans quelle mesure ces résultats correspondent à ceux obtenus sur une image radar réelle.

Pour ce faire, une zone particulièrement homogène a été sélectionnée sur une de nos images. Elle correspond à une zone de chatoiement totalement développé avec une densité de probabilité mesurée proche de l'équation 1.4 (fig.2.7, 2.8a et 2.8b).



a. Histogramme des amplitudes mesuré sur la zone test homogène.

b. Densité de probabilité théorique correspondant à une loi Gamma généralisée.

c. Fonction de répartition de l'amplitude théorique (ligne) et mesurée sur la zone homogène (points) ; leur différence est utilisée dans le test de Kolmogorov-Smirnov.

FIG. 2.8 – Étude de la zone-test de chatoiement pur.

Pour vérifier que cette zone suit bien la loi prévue, un test de Kolmogorov-Smirnov a

été réalisé. Soit  $\mathcal{H}_0$  l'hypothèse que cet échantillon suive la loi théorique de l'équation 1.4 et  $\mathcal{H}_1$  l'hypothèse qu'il ne la suive pas. On définit  $\alpha$  le risque de première espèce comme la probabilité de choisir  $\mathcal{H}_1$  alors que  $\mathcal{H}_0$  est vraie.

Le test de Kolmogorov est un test non-paramétrique d'ajustement à une distribution entièrement spécifiée (une loi gamma généralisée ici). Soit  $F_n^*$  la fonction de répartition empirique d'un  $n$ -échantillon d'une variable aléatoire de fonction de répartition  $F(x)$ , et soit  $D_n$  :

$$D_n = \sup |F_n^*(x) - F(x)|$$

Le test utilise la distribution asymptotique de  $D_n$  :

$$P(\sqrt{n}D_n < y) \rightarrow \sum_{k=-\infty}^{+\infty} (-1)^k e^{-2k^2 y^2} = K(y)$$

pour vérifier l'hypothèse  $\mathcal{H}_0$  [Sapo-78].

Le test de Kolmogorov-Smirnov effectué avec  $\alpha = 0.01$  a été positif, ce qui signifie que l'échantillon choisi a un comportement correspondant à la loi théorique avec un risque de première espèce de 1%.

Sur cette zone-test parfaitement homogène et qui ne contient donc aucune structure linéaire, nous avons calculé les taux de fausses alarmes en fonction du seuil de décision  $r_{min}$ , et nous les avons comparés aux taux théoriques.

Néanmoins, il nous faut tenir compte de la corrélation entre les pixels de l'image (voir §1.3.3) et utiliser le nombre de vues équivalent  $L_{eq}$  [Laur-89], [Nezr-92] :

$$L_{eq} = \frac{\frac{4}{\pi} - 1}{\gamma^2}$$

Cette estimation correspond à la méthode des moments, mais la méthode du Maximum de Vraisemblance pourrait également être utilisée [Brun-96].

Par ailleurs, nous supposons l'indépendance des pixels lorsque nous calculons les densités de probabilité des moyennes empiriques sur les zones 1, 2 ou 3. En réalité, pour tenir compte de la dépendance des pixels nous devons remplacer le nombre de pixels  $n_i$  par  $k_i n_i$ , avec  $k_i < 1$  puisque le nombre de pixels indépendants à l'intérieur d'une fenêtre diminue lorsque ces pixels sont corrélés. Ainsi, si on considère l'image moyennée obtenue en prenant des blocs de  $n_i$  pixels, le nombre de vues obtenu n'est pas la prévision théorique de  $n_i L_{eq}$  mais  $k_i n_i L_{eq}$ . Nous avons donc calculé  $L_{eq}$  sur toute l'image, et  $k_1, k_2$  et  $k_3$  avec  $n_1 = 33$ ,  $n_2 = n_3 = 22$  en réalisant des moyennages de l'image en blocs de  $n_i$  pixels. Nous avons obtenu  $L_{eq} = 2,74$  ;  $k_1 = 0,38$  ;  $k_2 = k_3 = 0,42$ . Les coefficients sont d'autant plus grands que les zones sur lesquelles ils sont calculés le sont.

Compte tenu des corrections mentionnées, les courbes de la figure 2.9a montrent un bon accord entre les résultats théoriques et ceux obtenus en pratique. Remarquons que si nous n'avions pas pris en compte ces corrections, comme c'est le cas dans [Cave-92], nous aurions trouvés des taux de fausse alarme empiriques bien plus importants que ceux prédits. Ceci s'explique par le fait que le nombre de pixels indépendants dans une région est bien inférieur au nombre total de pixels lorsque ceux-ci sont corrélés.

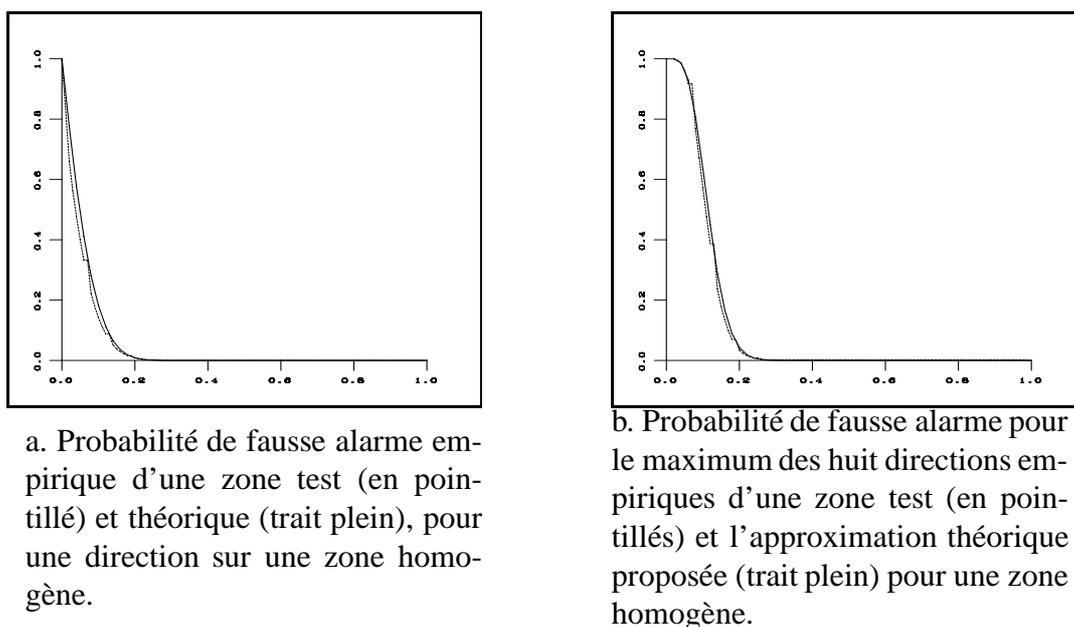


FIG. 2.9 – Probabilités de fausse alarme théoriques et empiriques de  $D1$ .

### 2.3.4 Cas de plusieurs directions

Les probabilités de fausse alarme et de détection données précédemment correspondent à une seule direction  $\vec{d}_k$ ; dans la pratique plusieurs directions ( $\mathcal{N}_d$ ) sont examinées. Les calculs théoriques sont dans ce cas trop complexes, les rapports calculés dans les différentes directions n'étant pas indépendants. Notons  $P_{\phi_{\mathcal{N}_d}}$  la probabilité de fausse alarme pour  $\mathcal{N}_d$  directions. Touzi [Touz-88b] a proposé l'expression empirique suivante pour le détecteur de contours :

$$P_{\phi_{\mathcal{N}_d}} = 1 - (1 - P_{\phi_1})^\alpha \quad (2.5)$$

avec  $\alpha = 3$ , lorsque  $\mathcal{N}_d = 4$ . Pour le détecteur de lignes, nous avons trouvé expérimentalement une expression similaire, avec  $\alpha = 5$  lorsque  $\mathcal{N}_d = 8$  (fig.2.9b). Les seuils de décision utilisés en pratique sont déduits de ces résultats.

## 2.4 Le détecteur de contours Dc2

Nous proposons dans cette partie un nouveau détecteur de contour que nous noterons Dc2. Son comportement est étudié statistiquement et des résultats sur des images réelles sont présentés.

### 2.4.1 Définition de Dc2

La démarche que nous avons adoptée est similaire en son principe à celle de Hueckel [Huec-71]. Nous cherchons à définir en un pixel  $x_0$  le contour qui approximera au mieux

la radiométrie de son voisinage  $V_{x_0}$  (typiquement une fenêtre carrée -fig.2.2). Un contour est supposé être une marche d'escalier ; c'est donc une ligne qui sépare deux zones  $i$  et  $j$  d'amplitudes constantes, et passe par  $x_0$ . Plutôt que de raisonner dans l'espace continu pour définir le contour idéal à partir de la radiométrie comme le fait Hueckel, nous avons choisi de nous limiter à un certain nombre de directions  $\vec{d}_k$ , et de raisonner dans l'espace discret. Sous ces hypothèses, et en choisissant de minimiser l'erreur quadratique moyenne (EQM), le contour idéal, correspondant à une direction  $\vec{d}_k$ ,  $k \in \{0, \dots, \mathcal{N}_d\}$ , a pour valeurs les moyennes empiriques  $\overline{A}_i$  et  $\overline{A}_j$  définies sur les zones  $i$  et  $j$  délimitées par la droite  $(\vec{d}_k, x_0)$  (voir figure 2.2). Par convention, la droite  $(\vec{d}_k, x_0)$  appartiendra toujours à la région  $j$ .

Une fois ce contour idéal défini, nous mesurons la pertinence de l'hypothèse de départ : *il existe un contour de direction  $\vec{d}_k$  passant en  $x_0$* . La comparaison entre le contour idéal et la zone de l'image dont il a été déduit se fait en évaluant le coefficient de corrélation centré et normalisé  $\rho_{ij}$  entre ces deux populations.

Considérons le cas d'une détection entre deux régions d'indices  $i$  et  $j$ . Le voisinage  $V_{x_0}$  est donc constitué de  $n$  échantillons de la variable aléatoire amplitude  $A$ , et nous nous donnons  $n$  échantillons de la variable aléatoire  $B$ , qui est le contour idéal pour  $A$  restreinte à  $V_{x_0}$ .  $B$  est bien une variable aléatoire puisqu'elle est fonction des moyennes empiriques  $\overline{A}_i$  et  $\overline{A}_j$  calculées sur les zones  $i$  et  $j$  qui suivent la distribution donnée par l'équation 2.1. Soit  $\sigma_A, \sigma_B, \overline{A}, \overline{B}$  les écart-types et les moyennes empiriques des deux populations,  $\rho_{ij}$  est obtenu par :

$$\rho_{ij} = \frac{1}{\sigma_A \sigma_B} \left( \frac{1}{n} \sum_{s \in V_{x_0}} A_s B_s - \overline{AB} \right) \quad (2.6)$$

En remplaçant les  $B_s$  par leurs valeurs pour notre modèle local (deux plages constantes égales à  $\overline{A}_i$  et  $\overline{A}_j$  de part et d'autre du contour), on obtient l'expression suivante de  $\rho_{ij}$  :

$$\rho_{ij}^2 = \frac{\sigma_B^2}{\sigma_A^2}$$

avec (en notant  $n = n_i + n_j$ ) :

$$\begin{aligned} \sigma_B^2 &= \frac{n_i n_j}{n^2} (\overline{A}_i - \overline{A}_j)^2 \\ \sigma_A^2 &= \frac{1}{n^2} \left( n_i n_j (\overline{A}_i - \overline{A}_j)^2 + n(n_i \sigma_i^2 + n_j \sigma_j^2) \right) \end{aligned}$$

On obtient finalement :

$$\rho_{ij}^2 = \frac{1}{1 + n\beta} \text{ avec } \beta = \frac{n_i \sigma_i^2 + n_j \sigma_j^2}{n_i n_j (\overline{A}_i - \overline{A}_j)^2}$$

En notant  $\overline{c}_{ij} = \frac{\overline{A}_i}{\overline{A}_j}$  le contraste "empirique" entre les régions  $i$  et  $j$ , et  $\gamma_i$  le coefficient de variation de la zone  $i$ , on obtient :

$$\beta = \frac{n_i \gamma_i^2 \overline{c}_{ij}^2 + n_j \gamma_j^2}{n_i n_j (\overline{c}_{ij} - 1)^2}$$

L'expression de  $\rho_{ij}$  ne fait donc pas intervenir le seul contraste, mais tient compte également de l'homogénéité des deux zones. Ce comportement est plus cohérent, puisque la présence d'un seul écho fort sur une région peut modifier complètement la valeur de Dc1. Remarquons que lorsque  $\overline{c_{ij}}$  tend vers 1, donc lorsque le voisinage  $V_{x_0}$  est totalement homogène,  $\beta$  tend vers  $+\infty$ , et donc  $\rho_{ij}$  tend vers 1, ce qui n'est pas particulièrement intuitif mais correspond bien à ce que nous souhaitons. Notons également que si nous avons choisi de prendre la covariance entre les échantillons de  $A$  et de  $B$ , c'est à dire le coefficient de corrélation non normalisé, le résultat aurait été totalement différent. On aurait eu  $\rho_{ij} = \sigma_B$ , ce qui serait revenu à prendre comme critère un simple gradient généralisé, inadapté à l'imagerie radar.

Remarquons aussi que le modèle explicitement défini ici est le même que celui utilisé par le détecteur Dc1. Mais la problématique est alors différente puisqu'on considère le voisinage global, et qu'on cherche à quantifier un changement à l'intérieur de ce voisinage. Notons également que le fait de ne pas considérer la droite  $(\vec{d}_k, x_0)$  implique que le détecteur de contour de Touzi aura forcément une réponse au moins double en présence d'un contour.

### 2.4.2 Probabilités de détection et de fausse alarme de Dc2

Il s'agit ici de réaliser une étude semblable à celle qui a été faite pour le détecteur de lignes D1, en calculant la densité de probabilité de  $\rho_{ij}$ , ainsi que les probabilités de détection et de fausse alarme. Comme pour l'étude précédente, les contours sont supposés séparer des zones totalement homogènes dont les pixels suivent une distribution gamma généralisée (éq.1.4). Malheureusement, l'expression de  $\rho_{ij}$  fait intervenir plusieurs variables aléatoires qui ne sont pas indépendantes entre elles ( $\overline{A}_i$  et  $\sigma_i$  sont liées). Même en faisant des approximations gaussiennes pour les distributions gammas généralisées, le calcul reste très complexe.

Pour avoir une idée du comportement du détecteur proposé, nous avons réalisé des simulations pour évaluer la densité de probabilité de  $\rho_{ij}$ ,  $f_{\rho_{ij}}(x|c_{ij})$  pour une valeur du contraste théorique  $c_{ij}$  entre les deux zones  $i$  et  $j$  fixée. Si cette démarche n'a pas la rigueur scientifique d'une expression explicite, elle permet néanmoins d'approximer les probabilités de détection et de fausse alarme, et de donner des ordres de grandeur pour le seuil de décision  $\rho_{min}$  (si  $\rho_{ij} > \rho_{min}$  un contour est alors détecté).

Les simulations ont été effectuées comme suit. Nous tirons pour chaque région  $i$   $n_i$  amplitudes selon la distribution de l'équation 1.4, et pour une intensité moyenne  $P_i$  choisie. Nous évaluons alors  $\overline{A}_i$  et  $\sigma_i$  pour en déduire une valeur de  $\rho_{ij}$ . Cette opération est répétée un très grand nombre de fois (de l'ordre de 100 000), et les fréquences d'apparition des différentes valeurs de  $\rho_{ij}$  entre 0 et 1 nous permettent d'approximer sa densité de probabilité.

Pour contrôler le résultat des simulations, nous avons d'abord approximé la densité de probabilité de Dc1 pour lequel nous disposons d'une expression explicite. La figure 2.10 montre la bonne correspondance entre la courbe théorique et la courbe déduite des simulations.

La figure 2.11a montre l'allure de la densité de probabilité simulée pour différents contrastes. La figure 2.11b montre les probabilités de détection; comme toujours la probabilité de détection augmente avec le seuil  $\rho_{min}$ . On remarque que seuls les contrastes su-

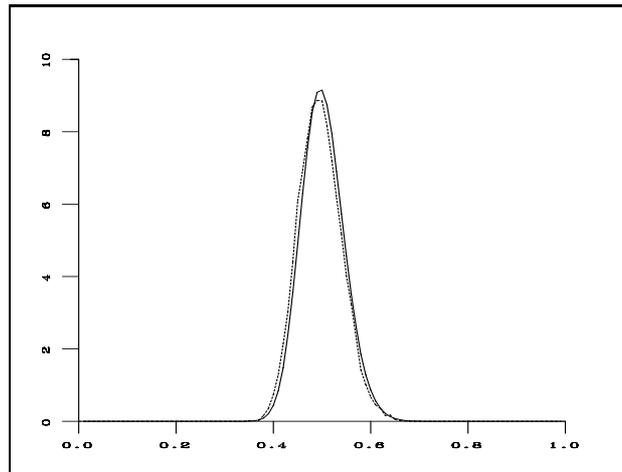


FIG. 2.10 – Densités de probabilité de  $r_{ij}$  théorique (trait plein) et déduite des simulations (en pointillés) pour  $L=3$ ,  $n_1 = n_2 = 22$ ,  $c_{ij}=2$ .

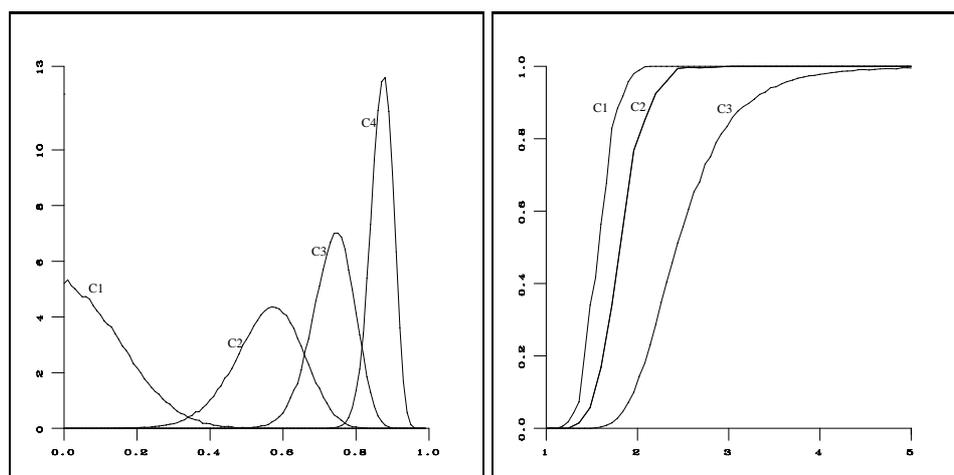
périeurs à 3 sont détectés avec une probabilité de plus de 90%, lorsque  $\rho_{min}=0,8$ . Par contre, lorsque  $\rho_{min}$  augmente, la probabilité de fausse alarme diminue (figure 2.11c). Suivant les objectifs fixés, ces courbes permettent de choisir la valeur de  $\rho_{min}$  la plus appropriée.

Là encore, pour vérifier que les résultats obtenus en pratique correspondent aux courbes théoriques, la probabilité de fausse alarme a été calculée sur la zone-test de chatoiement totalement développé (figure 2.11d). Les pixels de l'image PRI étant corrélés, la simulation a été adaptée. On a supposé que les cellules de résolution étaient de 25m sur 25, ce qui donne un recouvrement de 50% des cellules verticalement et horizontalement. Il s'agit d'une approximation, car la cellule de résolution a des dimensions de 18m en azimuth et de 22m (far range) à 29m (near range) en distance. Ainsi les réponses des réflecteurs élémentaires à l'intérieur d'une cellule de résolution ont été simulées (§ 1.3.1), et les réponses correspondant au recouvrement ont été conservées pour le tirage suivant. Une autre solution aurait été d'utiliser sur chaque région non pas  $n_i$  mais  $k_i n_i$  pixels (avec les  $k_i$  précédemment calculés). La courbe 2.11a est le résultat de la simulation. Les deux courbes obtenues sont proches (compte tenu de l'approximation assez grossière pour la corrélation des pixels) et surtout donnent la même limite, indiquant une probabilité de fausse alarme quasi nulle pour un seuil de décision de 0,6.

### 2.4.3 Application du détecteur de contours Dc2

Nous présentons ici les résultats obtenus par le détecteur de contour Dc2 sur une image ERS-1 (fig.2.12a).

Un des problèmes qui se posent lors de la détection de contour est le choix de la taille et de la forme des fenêtres. Celles-ci doivent être choisies pour contenir suffisamment de pixels dans chaque région tout en préservant la forme d'un contour ou d'une structure linéaire. En effet, plus le nombre de pixels utilisés dans le calcul des moyennes empiriques est grand, plus le taux de fausses alarmes est faible, comme on peut le voir sur les différentes courbes. Parallèlement, il faut que deux contours soient au moins distants d'une demi-largeur de

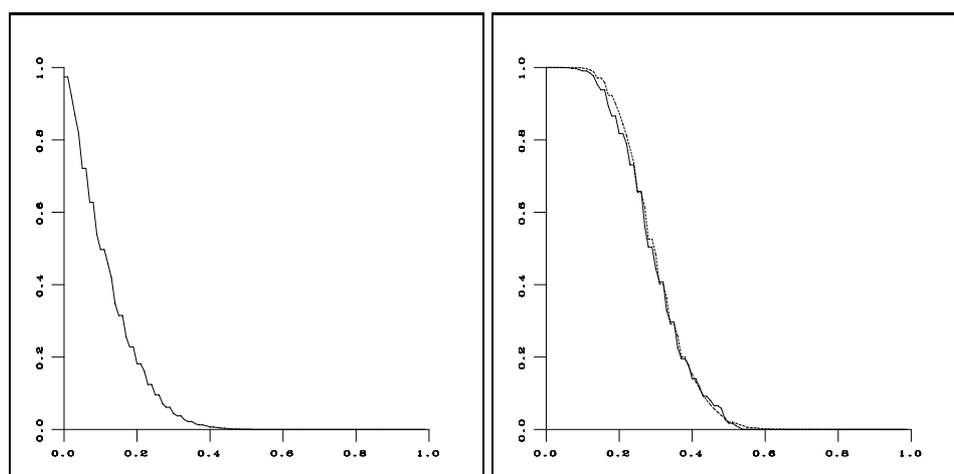


a. Densités de probabilité de  $\rho_{ij}$  pour différents contrastes :

$C_1$   $c_{ij}=1$  ;  
 $C_2$   $c_{ij}=1,5$  ;  
 $C_3$   $c_{ij}=2$  ;  
 $C_4$   $c_{ij}=4$ .

b. Probabilités de détection en fonction du contraste pour plusieurs valeurs du seuil de décision:

$C_1$   $\rho_{min}=0,6$  ;  
 $C_2$   $\rho_{min}=0,7$  ;  
 $C_3$   $\rho_{min}=0,8$ .



c. Probabilité de fausse alarme en fonction de  $\rho_{min}$  pour une direction ( $n_1 = n_2 = 22$ ).

d. Probabilités de fausse alarme en fonction de  $\rho_{min}$  pour les huit directions : simulée (trait plein) et empirique (en pointillés) avec  $n_1 = n_2 = 22$ .

FIG. 2.11 – Etude statistique du détecteur de contour Dc2

fenêtre pour être détectés. Nous avons donc choisi d'utiliser des masques rectangulaires plutôt que carrés, de longueur 7 ou 9 pixels et de largeur 6. Deux pixels de contours doivent ainsi être séparés par au moins deux pixels pour être détectés. La taille du masque impose en contre-partie d'augmenter le nombre de directions (huit ici).

Pour des raisons de simplicité et vu la taille du réseau auquel nous nous intéressons, nous nous sommes limités à des masques rectangulaires. Néanmoins, des masques comportant

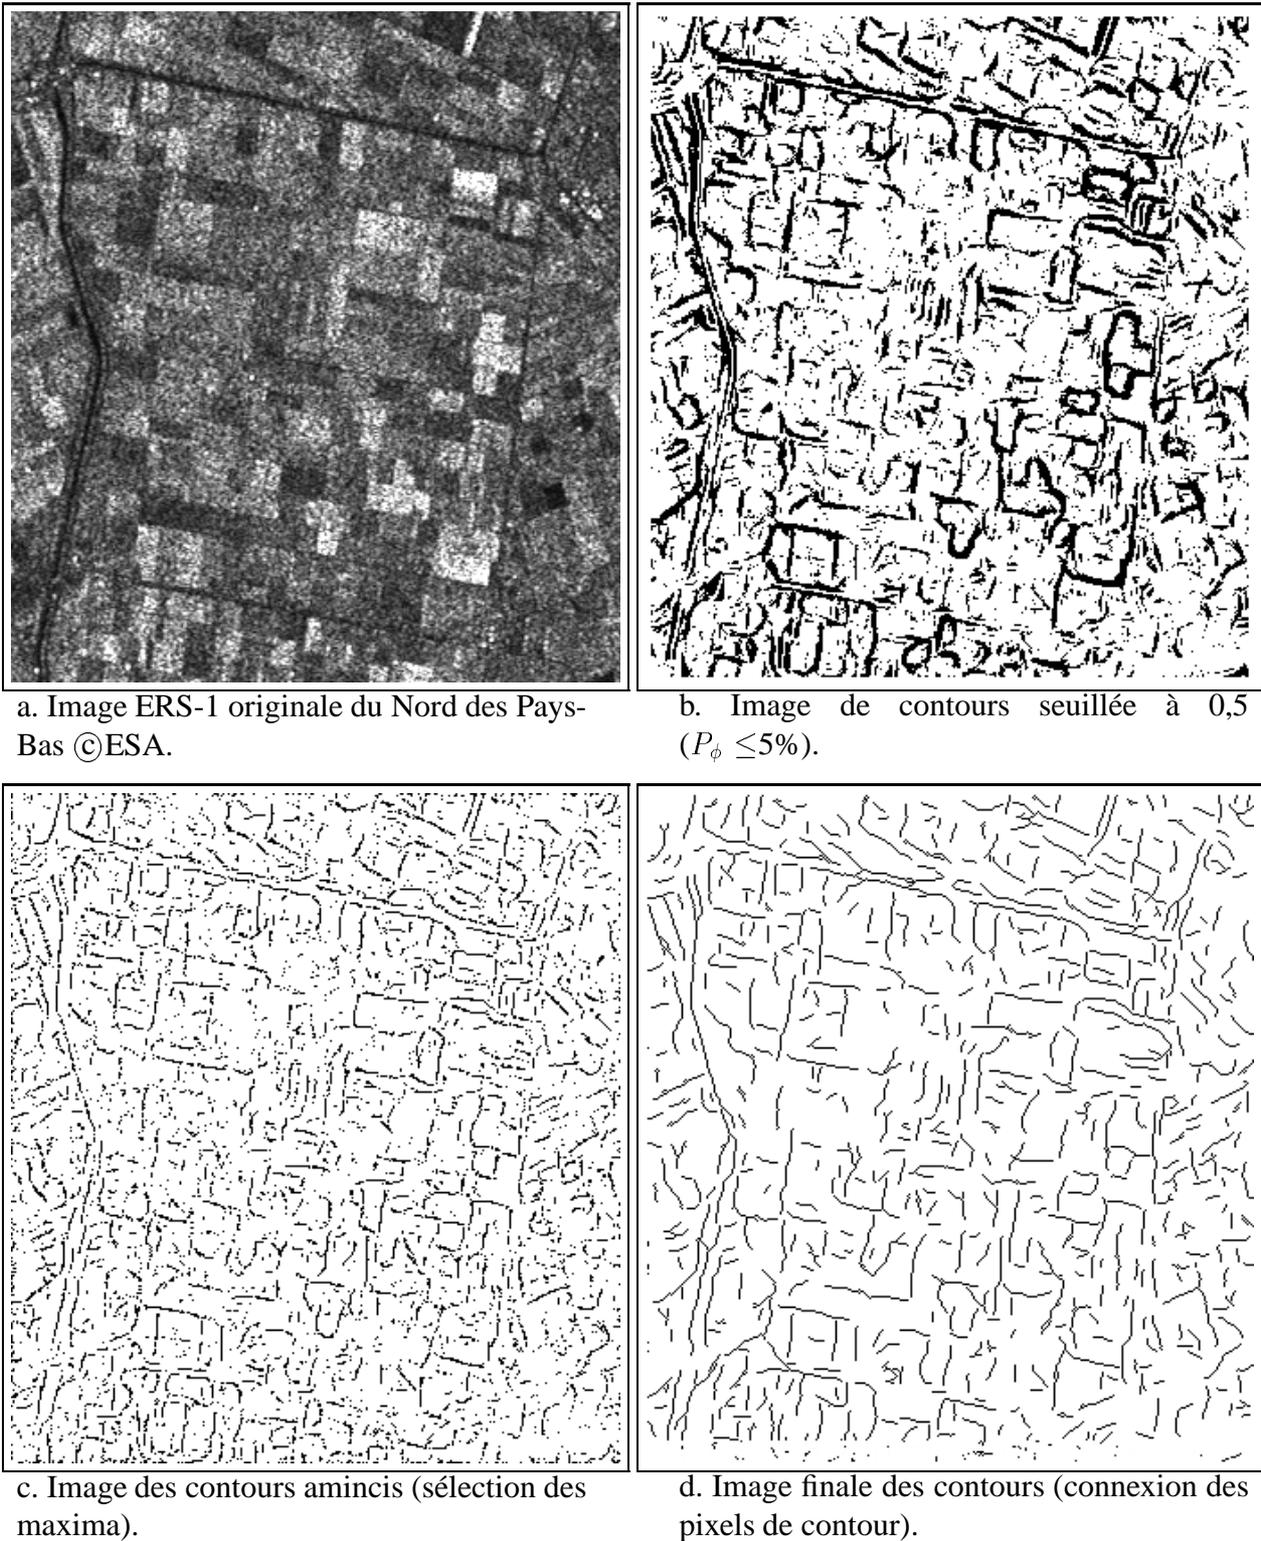


FIG. 2.12 – Détection de contours par le détecteur  $Dc2$

des parties courbes apporterait certainement une amélioration.

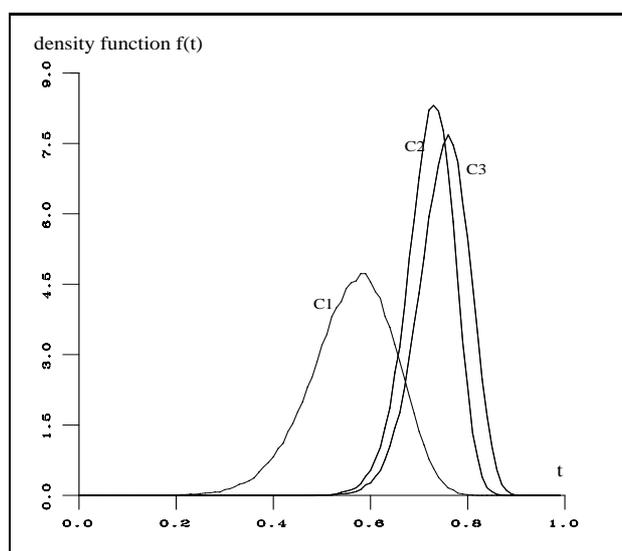
En ce qui concerne le choix du seuil de décision en pratique, si les études théoriques

permettent de donner un ordre de grandeur, il reste lié à l'application finale et surtout aux étapes de plus haut niveau qui suivent généralement la détection des lignes (cf. chapitre 3).

Un seuillage direct sur l'image des niveaux de gris donne des contours épais (fig.2.12b). Plutôt que d'utiliser un opérateur de morphologie mathématique [Touz-88a], nous avons sélectionné la réponse maximale du détecteur dans la direction perpendiculaire à la direction trouvée (fig.2.12c). De plus, pour obtenir les formes des contours, et pas seulement des pixels isolés, nous avons relié les pixels qui pouvaient l'être (voir §2.8).

Nous avons testé le détecteur sur des images de parcellaire (zone du Wieringermeer) où la présence de nombreux contours permet une bonne évaluation des performances (fig.2.12). Les résultats, notamment les contours des champs, sont satisfaisants mais la méthode de fermeture devrait pouvoir être améliorée.

## 2.5 Le détecteur de lignes D2



Densités de probabilité avec  $n_1 = 33$ ,  $n_2 = n_3 = 22$  pour différents contrastes :  $C_1$  pour  $c_{12} = 2$ ,  $c_{13} = 1, 5$  ;  $C_2$  pour  $c_{12} = c_{13} = 2$  ;  $C_3$  pour  $c_{12} = 2$ ,  $c_{13} = 4$ .

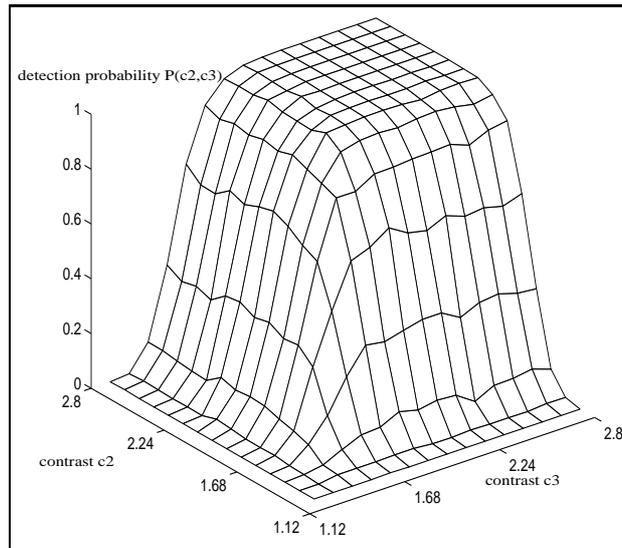
FIG. 2.13 – Densités de probabilité de D2.

De la même façon qu'au §2.3.1, nous définissons dans cette partie un nouveau détecteur de lignes s'appuyant sur le détecteur de contours proposé au §2.4.1. L'étude qui en sera faite sera tout à fait analogue à celle effectuée pour le premier détecteur de structures, et suivra les mêmes étapes.

En utilisant les notations de la figure 2.2, si  $\rho_{12}$  est la réponse du détecteur de contour entre les zones 1 et 2, et  $\rho_{13}$  entre les zones 1 et 3, le détecteur de structures  $\rho$  est :

$$\rho = \min(\rho_{12}, \rho_{13})$$

Là encore, cela revient à sélectionner la moins bonne des détections de contours comme résultat du détecteur de structures linéaires. Ceci nous assure que seules les lignes seront dé-



Probabilité de détection en fonction des contrastes  $c_{12}$  et  $c_{13}$  de part et d'autre de la structure pour un seuil  $\rho_{min} = 0.6$  et des fenêtres de taille  $n_1 = 33$ ,  $n_2 = n_3 = 22$

FIG. 2.14 – Probabilité de détection de D2 en fonction des contrastes.

tectées. Soit  $\rho_{min}$  un seuil de décision, seront considérés comme appartenant à une structure pour une direction  $\vec{d}_k$  donnée les pixels pour lesquels  $\rho > \rho_{min}$ .

Comme précédemment, la densité de probabilité de  $\rho$  sera déduite de simulations, ce qui nous permettra d'étudier les probabilités de détection et de fausse alarme du détecteur de structures, en fonction des contrastes entre les zones et du seuil de décision sur  $\rho$ .

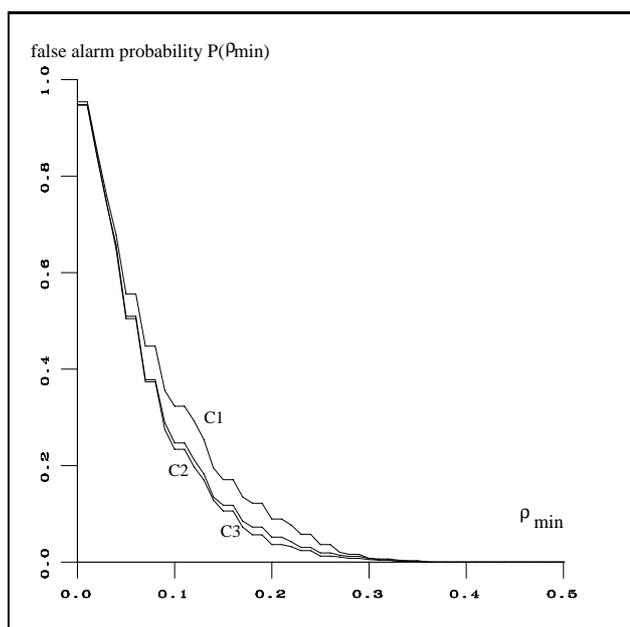
Dans le cas de zones homogènes, les résultats des deux détecteurs sont très proches, comme on peut le voir en comparant les figures 2.14 et 2.4, 2.15 et 2.5. Notons que pour les deux détecteurs, un taux de détection de l'ordre de 90 % nécessite un contraste relativement fort (pratiquement 2 dB) de part et d'autre de la structure linéaire.

Pour vérifier la correspondance entre résultats théoriques et empiriques la même zone-test a été utilisée. La prise en compte de la corrélation entre les pixels se fait comme précédemment. Là encore, on constate une bonne correspondance entre résultats empiriques et théoriques (fig.2.16a). La relation 2.5 est utilisée pour passer de une à huit directions (fig.2.16b).

## 2.6 Comparaison des détecteurs D1 et D2

Dans cette partie, nous comparons les performances des deux détecteurs. Les remarques faites sur les détecteurs de contours Dc1 et Dc2 se répercutent bien sûr de la même façon sur les détecteurs de lignes D1 et D2.

Tout d'abord, les hypothèses servant aux calculs des statistiques étant les mêmes dans les deux cas, les résultats théoriques sont sensiblement comparables. Cependant, sur les images réelles, la présence du coefficient de variation dans le détecteur Dc2 permet d'obtenir une

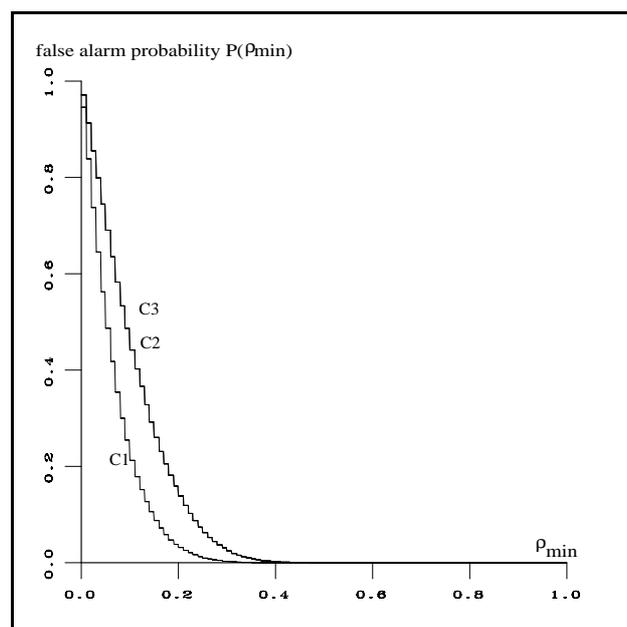


a. Influence du nombre de pixels sur  $P_\phi(\rho_{min}, 1)$  zone homogène ;

$C_1 : n_1 = 11, n_2 = n_3 = 33$  ;

$C_2 : n_1 = n_2 = 22, n_3 = 33$  ;

$C_3 : n_1 = 33, n_2 = n_3 = 22$ .



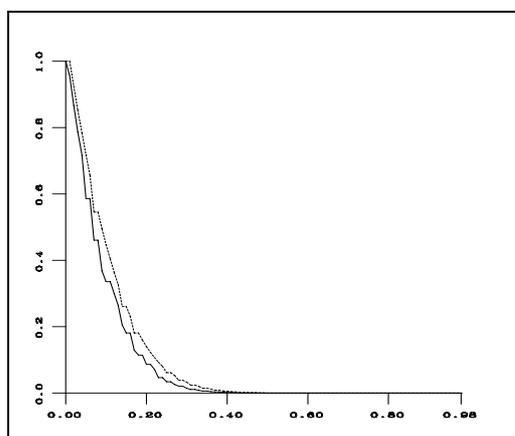
b. Influence du contraste  $c$  du contour sur  $P_\phi(\rho_{min}, c)$  ;

$C_1 : c = 1$  ;

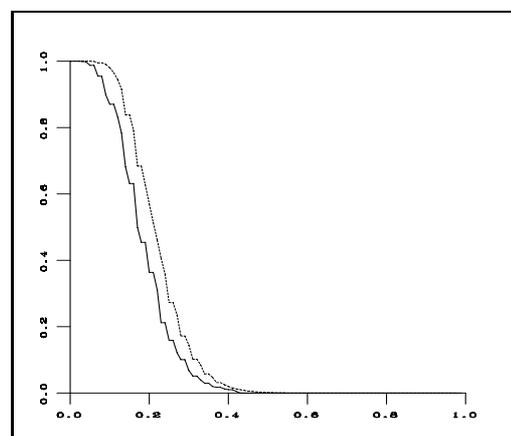
$C_2 : c = 2$  ;

$C_3 : c = 4$ .

FIG. 2.15 – Probabilités de fausse alarme  $P_\phi(\rho_{min}, c)$  de D2 en fonction du seuil de décision  $\rho_{min}$  pour différents jeux de paramètres.



a. Probabilité de fausse alarme empirique d'une zone test (en pointillé) et théorique (trait plein), pour une direction sur une zone homogène.



b. Probabilité de fausse alarme pour le maximum des huit directions empiriques d'une zone test (en pointillés) et l'approximation théorique proposée (trait plein) pour une zone homogène.

FIG. 2.16 – Probabilités de fausse alarme théoriques et empiriques de D2.

réponse plus précise que celle de Dc1. En effet, pour des pixels distants de un ou deux pixels d'un contour (fig.2.17), non seulement le contraste diminue mais les coefficients de variation

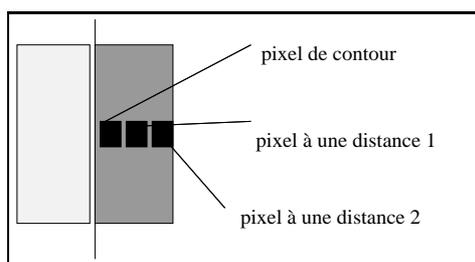
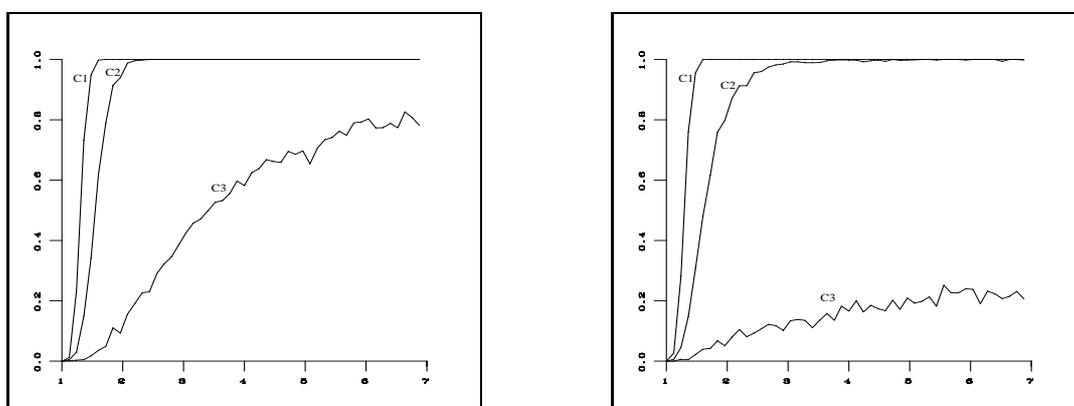


FIG. 2.17 – Exemples de pixels distants du contour.

a. Probabilités de détection en fonction de  $c$  pour Dc1.b. Probabilités de détection en fonction de  $c$  pour Dc2.

$C_1$  pour le pixel de contour ;  
 $C_2$  pour un pixel à une distance 1 du contour ;  
 $C_3$  pour un pixel à une distance 2 du contour.

FIG. 2.18 – Comparaison des détecteurs de contours Dc1 et Dc2.

des deux zones augmentent, les deux effets se conjuguant pour diminuer la réponse de Dc2 (fig.2.18 et fig.2.19).

Cette remarque est également valable lorsqu'une des zones contient un très fort réflecteur, cas où la réponse de Dc1 peut être favorable mais non celle de Dc2. Si le détecteur Dc2 est plus précis au niveau spatial, Dc1 est cependant plus sensible au niveau radiométrique, et moins tributaire des hypothèses. De plus, comme nous l'avons déjà souligné, il faut inclure la droite  $(\vec{d}_k, x_0)$  pour supprimer une des réponses du détecteur Dc1 (fig.2.19).

La figure 2.20 illustre ces propos sur D1 et D2. Les seuils de décision utilisés pour le seuillage ont été choisis de façon à assurer une probabilité de fausse alarme inférieure à 5%. Le détecteur D1 donne des réponses moins précises, mais il est moins sensible à l'hypothèse de régions homogènes, comme on peut le constater dans la partie en haut à droite de l'image où des réflecteurs spéculaires sont situés le long de la route.

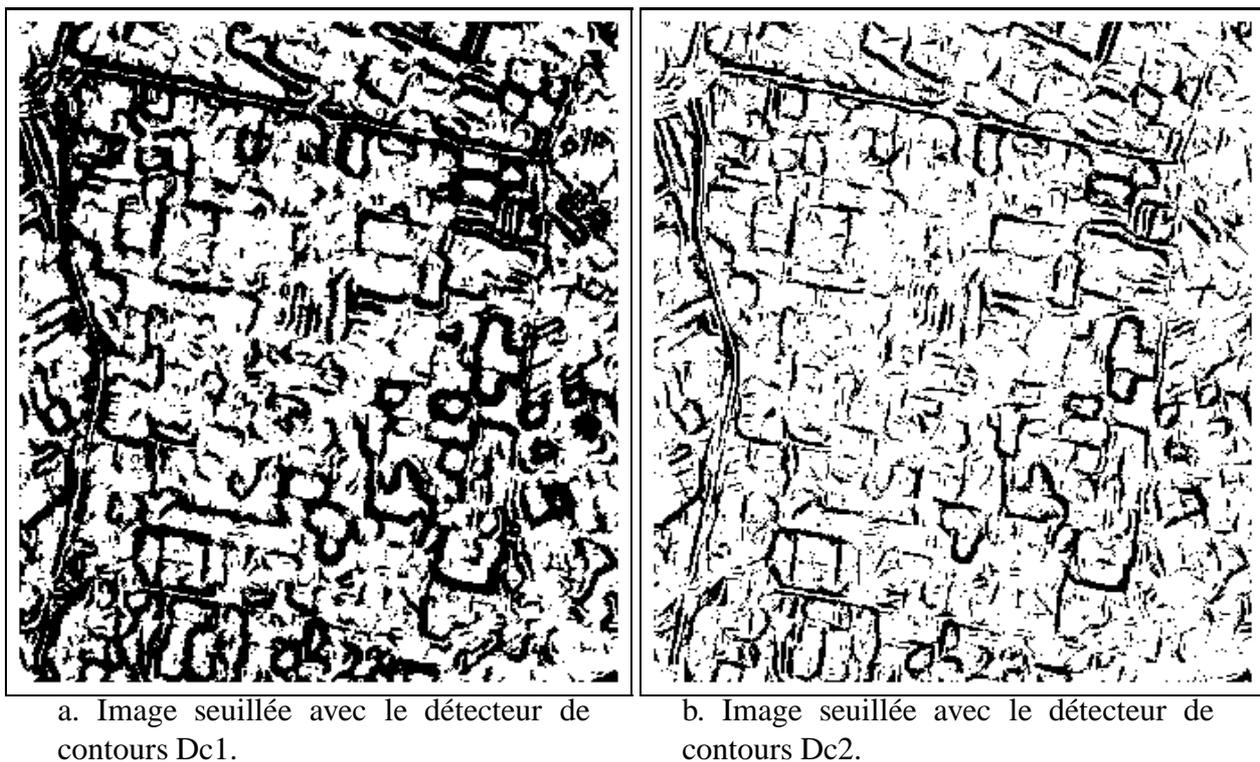


FIG. 2.19 – Comparaison des détecteurs Dc1 et Dc2.

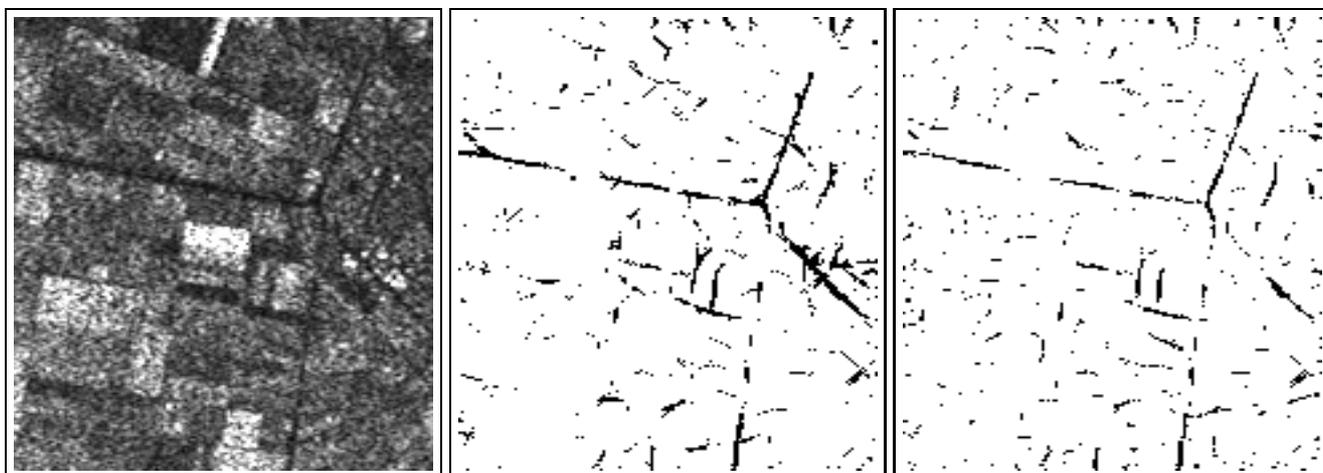
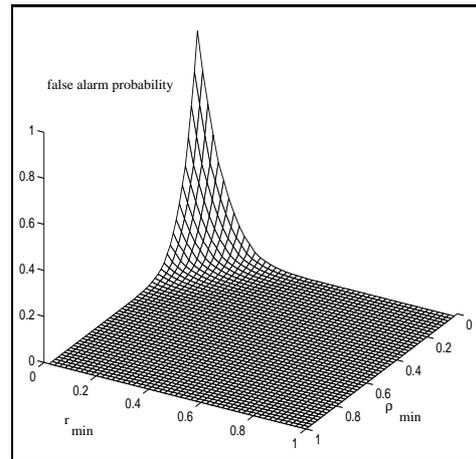


FIG. 2.20 – Comparaison des détecteurs D1 et D2.

## 2.7 Fusion des réponses de D1 et D2

Plutôt que de choisir un des détecteurs, nous avons préféré combiner les mesures de D1 et D2. Les réponses des deux détecteurs  $r$  et  $\rho$  sont donc fusionnées dans chaque direction  $\vec{d}_k$ , ( $k \in \{0, \dots, \mathcal{N}_d\}$ ) testée.



a. Probabilité de fausse alarme sur une zone homogène.

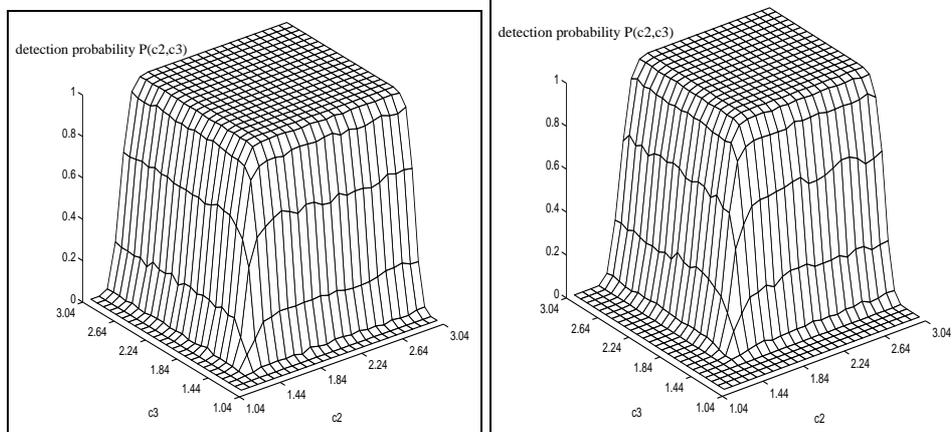
b. Probabilité de détection pour  $r_{min} = 0,25$  et  $\rho_{min} = 0,45$ .c. Probabilité de détection pour  $r_{min} = 0,3$  et  $\rho_{min} = 0,6$ .

FIG. 2.21 – Comportement de la fusion des réponses de D1 et D2

Nous avons choisi d'utiliser une somme associative symétrique  $\sigma(x, y)$ , qui est définie par [Bloc-96] :

$$\sigma(x, y) = \frac{xy}{1 - x - y + 2xy} \quad x, y \in [0, 1] \quad (2.7)$$

Nous avons choisi cet opérateur de fusion car il a une attitude disjonctive (indulgente) pour de fortes valeurs des mesures ( $x > 0,5$  et  $y > 0,5$ ), conjonctive (sévère) pour de faibles valeurs ( $x < 0,5$  et  $y < 0,5$ ), et adaptative en fonction des valeurs  $x$  et  $y$  dans tous les autres cas [Bloc-96].

Comme le comportement de cet opérateur dépend de la position des variables par rapport à  $0,5$ , nous avons d'abord recentré les réponses obtenues autour des seuils de décision des détecteurs. Ainsi,  $\tilde{r} = r + 0,5 - r_{min}$  et  $\tilde{\rho} = \rho + 0,5 - \rho_{min}$  (éventuellement seuillées entre 0 et 1) sont utilisées dans l'équation 2.7. Ensuite, le seuil de décision utilisé sur la fusion des deux réponses est automatiquement la valeur centrale  $0,5$  de l'intervalle  $[0, 1]$ .

Ici encore, puisque les variables  $\tilde{r}$  et  $\tilde{\rho}$  ne sont pas indépendantes, il est difficile de trouver

une expression analytique de la densité de probabilité de  $\sigma(\tilde{r}, \tilde{\rho})$ . Aussi des simulations ont-elles été utilisées pour étudier le comportement de cette fusion. De plus, la probabilité de fausse alarme est ici fonction des seuils de décision de D1 et D2,  $r_{min}$  et  $\rho_{min}$  ; un exemple dans le cas d'une zone parfaitement homogène est montré sur la figure 2.21a. Deux exemples de la probabilité de détection pour des seuils de décision différents sont montrés figures 2.21b et c. On constate comme prévu que la diminution des seuils de décision entraîne une augmentation de la probabilité de détection pour des contrastes faibles.

Finalement, pour obtenir une unique réponse à la détection de lignes en chaque pixel, la mesure de fusion la plus forte sur toutes les directions testées est conservée, ainsi que la direction associée  $\vec{d}_k$ ,  $k \in \{0, \dots, 7\}$ . L'image des mesures est alors seuillée avec un seuil de 0,5. Les pixels conservés sont considérés comme des éléments de structure possible, et leur direction est stockée. Cette étape est illustrée fig.2.22.

Remarquons par ailleurs que l'opérateur de fusion utilisé, appliqué à des images réelles, a donné de meilleurs résultats que de simples opérateurs logiques ET ou OU, qui sont trop sévère ou trop indulgent.

## 2.8 Des pixels aux segments

Les traitements décrits dans cette partie ont pour but d'effectuer le changement de primitives, nous permettant ainsi de passer de la notion de pixel appartenant à une ligne à celle de segment de structure linéaire. Les opérations de plus haut niveau qui sont décrites dans le prochain chapitre (chapitre 3), et qui réalisent l'opération de fermeture, travaillent sur ces segments.

Il s'agit donc ici d'effectuer des post-traitements permettant de supprimer une partie du bruit et des fausses alarmes en utilisant des observations simples.

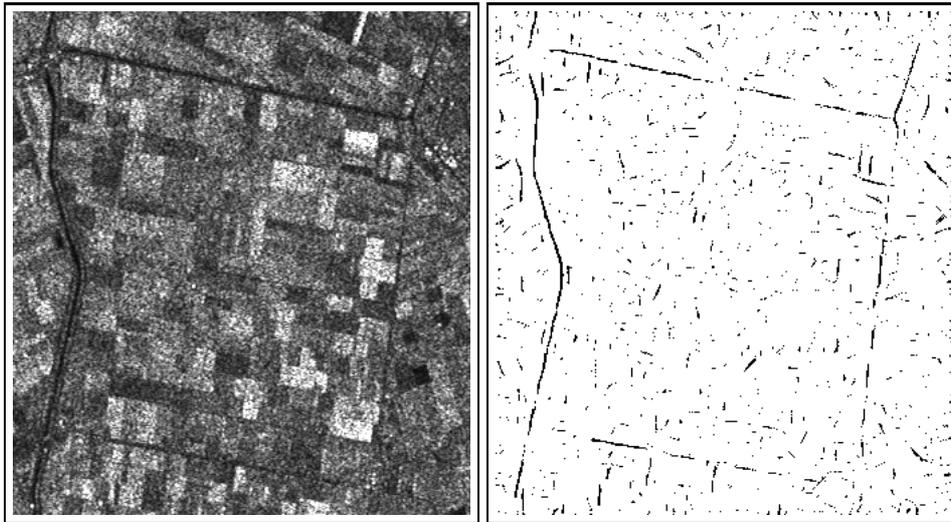
### 2.8.1 Suppression des pixels isolés

La première étape consiste à supprimer les pixels classés éléments de structures qui sont "isolés". Notons  $\vec{d}_k$  la direction associée à un pixel  $x_0$ . Les directions des pixels contenus dans un faisceau angulaire (l'angle du faisceau est de plus ou moins  $22,5^\circ$ ) autour de  $\vec{d}_k$  sont recensées. Si on retrouve la direction  $\vec{d}_k$  ou les deux plus proches directions voisines ( $\vec{d}_{k-1}$  et  $\vec{d}_{k+1}$ ) dans une proportion supérieure à un seuil, le pixel  $x_0$  est considéré comme non isolé<sup>4</sup> ; sinon, il est supprimé. On obtient donc une image binaire et une image de directions.

### 2.8.2 Transformée de Hough locale

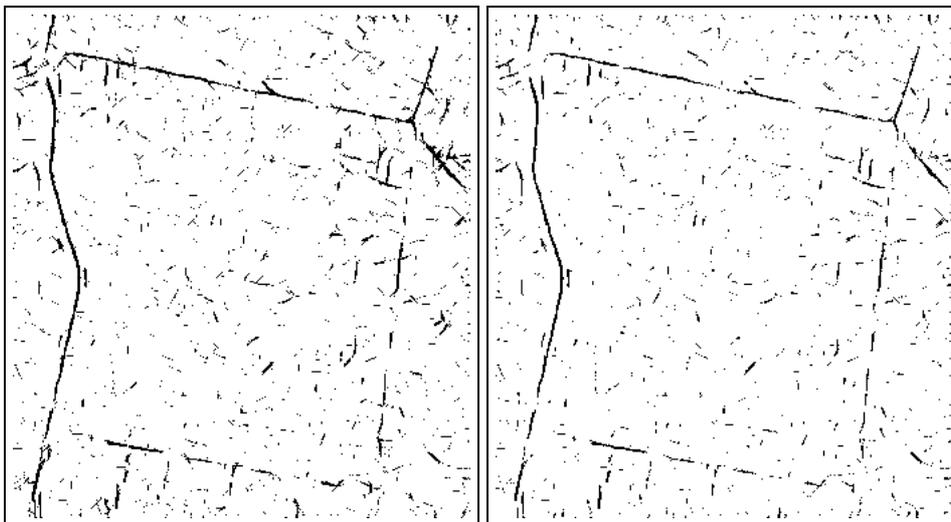
La deuxième étape consiste à appliquer une transformée de Hough locale pour permettre une nouvelle réduction du nombre de pixels à traiter. L'image est divisée en blocs de pixels  $20 \times 20$  avec un recouvrement de moitié. Sur chaque bloc une transformée de Hough simplifiée est appliquée. Plutôt que de considérer toutes les directions possibles, seules celles

4. Les directions obtenues sont discrètes, ce sont celles utilisées pour D1 et D2.



a. Image ERS-1 originale du Nord des Pays-Bas ©ESA.

b. Seuillage des réponses du détecteur D2.



c. Seuillage des réponses du détecteur D1.

d. Seuillage de la fusion des réponses à D1 et D2.

FIG. 2.22 – *Résultat de la fusion*

utilisées pour les deux détecteurs sont retenues. L'accumulateur est ainsi simplifié et ne tient compte que des droites ayant l'une des huit directions utilisées pour D1 et D2 et passant par la fenêtre d'étude [Jedy-91]. Chaque pixel  $x_0$  de l'image binaire vote alors pour la direction  $\vec{d}_k$  qui lui est associée. La position de la droite de direction  $\vec{d}_k$  passant par le maximum de points est déterminée. Les points n'appartenant pas à cette droite (élargie sur trois pixels pour atténuer les problèmes liés à la discrétisation) sont ensuite supprimés.



a. Résultat après l'ensemble des post-traitements.      b. Résultat après la squelettisation.

FIG. 2.23 – Résultats de la connexion locale et de la squelettisation

### 2.8.3 Obtention des segments

Les deux premières étapes ont permis la suppression des pixels ou groupes de pixels "isolés", détectés de façon locale comme éléments de structure par l'un des deux détecteurs. En réalité, l'image est encore constituée de pixels disjoints ou de petits groupes de pixels. Il s'agit dans cette étape de lier les pixels de directions identiques ou voisines, en prospectant, en un pixel de direction  $\vec{d}_k$ , dans un faisceau angulaire centré sur  $\vec{d}_k$  (l'angle du faisceau est de plus ou moins  $22,5^\circ$ ). L'image est balayée dans sa globalité une seule fois. En chaque pixel  $s$  sélectionné par les étapes précédentes, une prospection est effectuée de façon locale. Lorsqu'un pixel  $t$  de direction proche (les deux directions voisines de la direction principale étant admises) est détecté dans la surface angulaire, les deux pixels sont "chaînés", et la prospection continue à partir du site  $t$ . Notons que le parcours du faisceau angulaire se fait par ordre de priorité décroissante sur les pixels (les pixels les plus au centre du faisceau étant prioritaires). On obtient des composantes connexes très étirées. Ne sont conservées que celles dont la longueur est suffisante par rapport à un seuil donné.

L'image binaire résultat est ensuite squelettisée ; nous avons choisi l'algorithme THNG3 de la librairie de traitement d'images SPIDER, qui correspond à l'algorithme décrit par Deutsch [Deut-72]. Les pixels sont ensuite chaînés, puis pour chaque chaîne on utilise une approximation polygonale avec la méthode de la corde pour déterminer des segments de droite [Roux-92].

Les trois étapes de post-traitements (suppression des pixels isolés, transformée de Hough locale et liaison des pixels) et l'étape de squelettisation sont illustrées fig.2.23a et fig.2.23b.

## 2.9 Conclusion

Le problème de la détection des structures linéaires sur les images radar est un problème rendu particulièrement difficile par le phénomène de chatoiement. Devant l'échec des détecteurs classiquement utilisés en traitement d'images qui supposent des bruits blancs gaussiens, nous apportons dans ce chapitre une réponse à la détection des structures linéaires dans un voisinage local de chaque pixel, en proposant la fusion de deux détecteurs de lignes adaptés aux statistiques des images radar. Ce choix est accompagné par une étude théorique et expérimentale poussée des comportements des détecteurs et de leur fusion en adoptant un modèle de chatoiement totalement développé. Cette étude permet de déterminer les conditions d'utilisation en fonction des performances souhaitées et de réaliser le compromis le plus adapté. Elle met également en évidence les limites de la méthode lorsque les contrastes de part et d'autre d'une ligne sont insuffisants. Pour cette raison, nous verrons dans les chapitres suivants (3 et 4) qu'une étape de plus haut niveau est nécessaire à l'exploitation efficace des résultats obtenus.

Par ailleurs, le chapitre 4, qui est dédié à l'application des outils développés aux chapitres 2 et 3, illustrera les performances et les limites de la méthode de détection de lignes proposée ici sur plusieurs images radar et dans des situations plus variées que celles présentées jusqu'à présent.

## Chapitre 3

# Une méthode de connexion markovienne

*Cette partie présente une méthode originale de connexion du réseau (routier ou fluvial) à partir d'une détection de segments. Le problème est ramené à l'étiquetage d'un graphe dont le champ d'étiquettes est supposé markovien. Après avoir exposé les objectifs et les hypothèses de notre démarche, nous détaillons la construction du graphe de segments. L'équivalence champ de Markov - champ de Gibbs ramène alors le problème à la minimisation d'une énergie que nous définirons. L'analyse du rôle des paramètres et l'étude de configurations extrêmes nous permettent de fixer des intervalles de choix. Les différentes étapes de notre démarche sont illustrées par un exemple de détection du réseau routier.*

### 3.1 Présentation du problème

L'objectif est ici de proposer une méthode capable de donner une interprétation de l'image en termes d'"objets linéaires longs" à partir d'une détection de lignes de bas-niveau. Ces objets sont notés  $Obl$  dans la suite<sup>1</sup>. Malgré l'utilisation de détecteurs de lignes adaptés au chatoiement, la détection des structures linéaires sur les images ROS reste relativement médiocre et ses résultats sont loin de ceux obtenus en imagerie satellitaire optique. La technique que nous proposons a été développée pour gérer des détections de bas-niveau de mauvaise qualité avec de nombreuses fausses alarmes (souvent dues à des structures locales) et peu de segments appartenant aux structures qu'on souhaite détecter.

D'une façon générale, toutes les techniques de détection de contours ou de structures faisant appel à des détecteurs locaux sont ensuite confrontées au problème du passage de la représentation locale à la représentation globale [Davi-90] [Pare-89] [Lowe-89]. Cox [Cox-93] par exemple utilise le parcours d'un arbre d'hypothèses recensant toutes les segmentations possibles de la scène. Mais les problématiques sont souvent plutôt celles de l'interprétation d'une image de haute qualité à partir d'une détection de contours presque sans bruit, ce qui est loin d'être notre cas. Notons que les snakes [Kass-88] apportent également une solution à ce problème puisqu'on part d'une représentation globale évoluant sous des contraintes locales ; mais alors une seule courbe (ou un seul contour) est détecté à la fois. Dans le cas des

---

1. Il peut s'agir par exemple des réseaux routiers ou fluviaux qui ont été étudiés dans cette thèse ; mais on pourrait envisager d'autres applications, comme la détection de bâtiments.

images ROS, le procédé de groupement perceptuel permet souvent à l'œil de retrouver les réseaux. Il serait intéressant d'essayer des approches tirées de la "Gestalt Theory" [Hera-92] [Mang-92] [Mang-94], même s'il est probable qu'elles se heurteront à la complexité des images étudiées et à la variabilité des réseaux.

Nous avons préféré adopter une approche markovienne, la souplesse de ce cadre permettant l'introduction de connaissances a priori très variées [Mang-95b]. En effet, une connaissance a priori contextuelle sur un voisinage restreint est généralement suffisante pour identifier un Obl, qu'il s'agisse d'une route ou d'une rivière. Ainsi, nous construisons un graphe de segments à partir des primitives détectées. Le processus d'identification des routes est alors ramené à un problème d'étiquetage ("Obl" ou "non-Obl") des sommets du graphe, et le champ d'étiquettes est markovien. Par convention, dans toute la suite, l'étiquette 1 correspond à des segments Obl, et 0 aux autres.

Les techniques markoviennes sont très fréquemment utilisées en traitement d'images depuis une dizaine d'années, en particulier pour la restauration [Gema-84]. En imagerie, les processus aléatoires sont généralement indicés par l'ensemble des sites ou pixels de l'image, mais ils peuvent l'être par toutes les primitives extraites, ou plus généralement par n'importe quel ensemble de sommets d'un graphe. A titre d'exemples, on peut trouver des approches markoviennes considérant des régions [Kim-93] [Gera-95] ou des objets aléatoires reliés par des relations elles-mêmes variables aléatoires [Azen-92a] [Mang-95a]. Mentionnons également les travaux considérant des sites-segments : Geman et Geman [Gema-84] associent au processus intensité un processus ligne améliorant la détection des contours ; Marroquin [Marr-89] [Urag-94] propose un champ de Markov sur des pixels considérés comme éléments de lignes, donc très local. Après la première étape, il était naturel ici de considérer un graphe dont les sommets seraient des segments. Contrairement aux deux approches précédentes, les sites-segments ne correspondent pas aux pixels de l'image, mais à des groupes de plusieurs pixels (au moins trois) ; le graphe qui en résulte a alors une topologie non-uniforme. Le voisinage que nous définissons a une dimension locale par rapport aux Obl que nous voulons détecter, tout en étant plus global que les masques des détecteurs de lignes.

## 3.2 Définition du graphe

Parmi les segments obtenus par la phase locale décrite au chapitre 2, certains appartiennent aux Obl à détecter, quand d'autres sont de fausses détections. En outre, une grande partie des segments constituant les Obl n'a pas été détectée. Nous émettons l'hypothèse fondamentale que les Obl peuvent être obtenus simplement en connectant certains segments détectés d'une manière adéquate, et en rejetant les fausses alarmes qui ne peuvent être connectées. Cette hypothèse impose que les segments détectés suivent, même avec de grandes interruptions, les circonvolutions des Obl.

Ainsi, nous ne recherchons plus les Obl sur toute l'image, mais seulement sur les primitives obtenues et sur l'ensemble des connexions possibles entre ces primitives. Nous restreignons donc l'espace image à un ensemble de segments  $S$ . Notons  $S_d$  l'ensemble des segments détectés lors de la première étape. Nous ajoutons à  $S_d$  l'ensemble  $S'_d$  des connexions possibles. Plusieurs contraintes peuvent guider la définition d'une "connexion possible". Par

exemple, dans le cas où les Obl sont des routes, on peut la définir par les trois contraintes suivantes :

- ◇ elle relie les extrémités de deux segments distincts
- ◇ ces extrémités sont suffisamment proches (i.e la distance les séparant est inférieure à un seuil  $D_{max}$  fixé)
- ◇ les segments qu'elle relie sont "alignés"

L'alignement est défini de la façon suivante. Soient deux segments  $s_1$  et  $s_2$  reliés par un segment intermédiaire  $s_i$  et soit  $\theta_1$ ,  $\theta_2$  et  $\theta_i$  leurs angles respectifs avec l'horizontale (fig.3.1). Pour que  $s_1$  et  $s_2$  soient considérés comme alignés, il faut que  $\theta_i$  soit compris entre  $\min(\theta_1, \theta_2)$  et  $\max(\theta_1, \theta_2)$  [Roux-92].

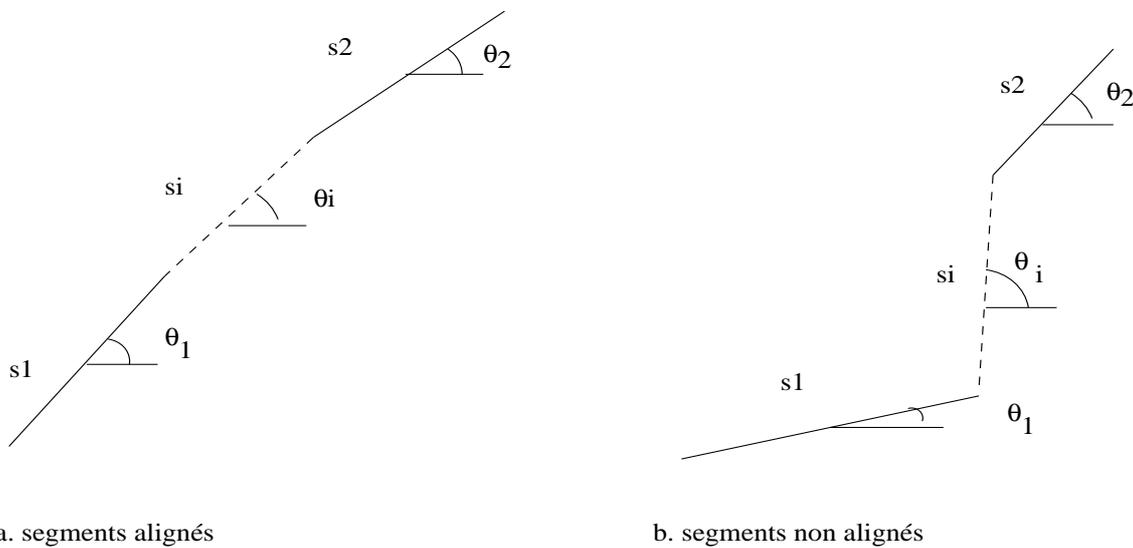


FIG. 3.1 – *Alignement des segments*

Dans le cas des Obl fleuves, on peut envisager de relâcher la dernière contrainte, les circonvolutions pouvant être importantes.

Soit  $i$  un segment de  $S_d$ , et  $M_i^k$  l'extrémité  $k$  ( $k \in \{1, 2\}$ ) du segment  $i$ , en notant  $i\mathcal{C}j$  une connexion possible entre les segments  $i$  et  $j$ , nous définissons  $S'_d$  par :

$$S'_d = \{M_i^k M_j^l, i \in S_d, j \in S_d \text{ et } i\mathcal{C}j\}$$

Et nous construisons le graphe des segments  $S$  par :

$$S = S_d \cup S'_d$$

En fait, ce graphe est le dual du graphe des extrémités  $M_i^k$  reliées par les segments de  $S$  (où la dualité est ici définie par rapport aux sommets et aux arcs).

Si on considère le graphe complet  $S_c$  ayant pour sommets les segments provenant de toutes les connexions possibles entre points extrémités  $M_i^k$ ,  $S$  est un sous-graphe extrait de  $S_c$ , soumis à des contraintes géométriques. La construction du graphe est illustrée sur les figures 3.2 et 3.3.

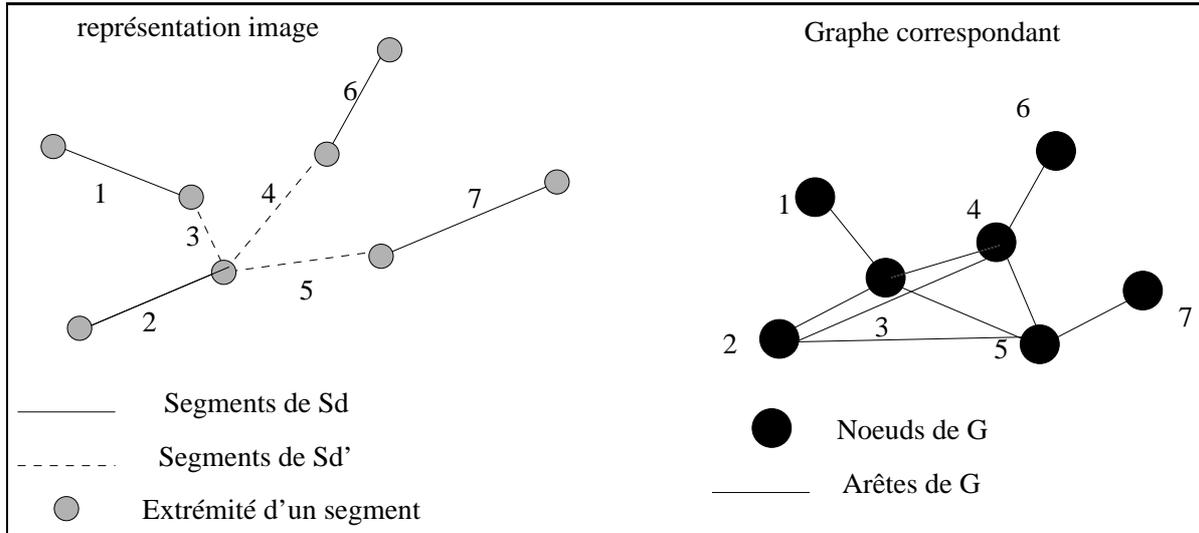


FIG. 3.2 – Construction du graphe de segments

$S$  est muni d'une structure de graphe  $G = \{S, A\}$ , chaque segment  $i$  de  $S_d$  ou  $S_d'$  étant un sommet, et deux sommets  $i$  et  $j$  étant reliés par une arête de  $A$  s'ils partagent un même point extrémité.

$$\mathcal{V}_i = \{j \in S / \exists p, k \in \{1, 2\}, M_i^k = M_j^p, i \neq j\}$$

Ainsi, les cliques du graphe sont les ensembles de segments partageant une extrémité<sup>2</sup>, plus les singletons.

Pour pouvoir tenir compte par la suite de la géométrie dans l'image d'origine, nous allons définir un graphe attribué  $G_a$ . A chaque sommet  $i$  est associé sa longueur  $\mathcal{L}_i$ , et à chaque arête  $(i, j)$  l'angle  $\mathcal{R}_{ij}$  mesuré modulo  $\pi$  entre les deux segments de l'image.

La détermination dans  $S$  des sommets appartenant à un Obl va constituer l'étape suivante. Nous allons associer à tout élément de  $S$  une variable aléatoire  $L_i$  pouvant prendre ses valeurs dans  $\{0, 1\}$ . Le processus aléatoire<sup>3</sup>  $L = (L_1, L_2, \dots, L_N)$  prend donc ses valeurs dans  $\Omega$ , espace de toutes les configurations possibles de cardinal  $2^N$  où  $N = \text{card}(S)$ .

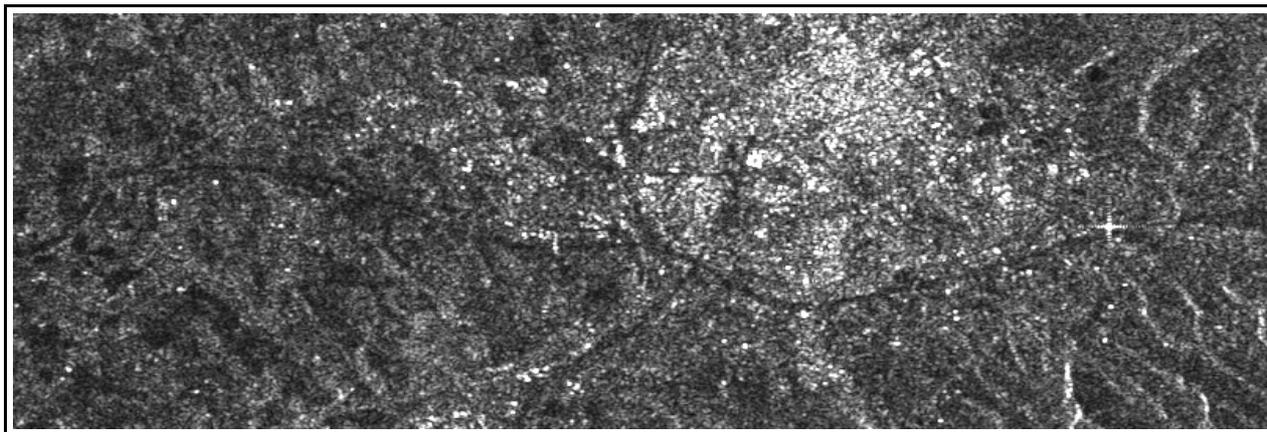
Nous cherchons donc à calculer la réalisation de  $L$  la plus probable, connaissant des observations ou données  $D$  sur les segments de  $S$ . En adoptant le critère du maximum a posteriori (MAP), nous voulons maximiser la probabilité  $p(L|D)$  appelée probabilité a posteriori qui s'écrit, d'après la règle de Bayes :

$$p(L|D) = \frac{p(D|L)p(L)}{p(D)}$$

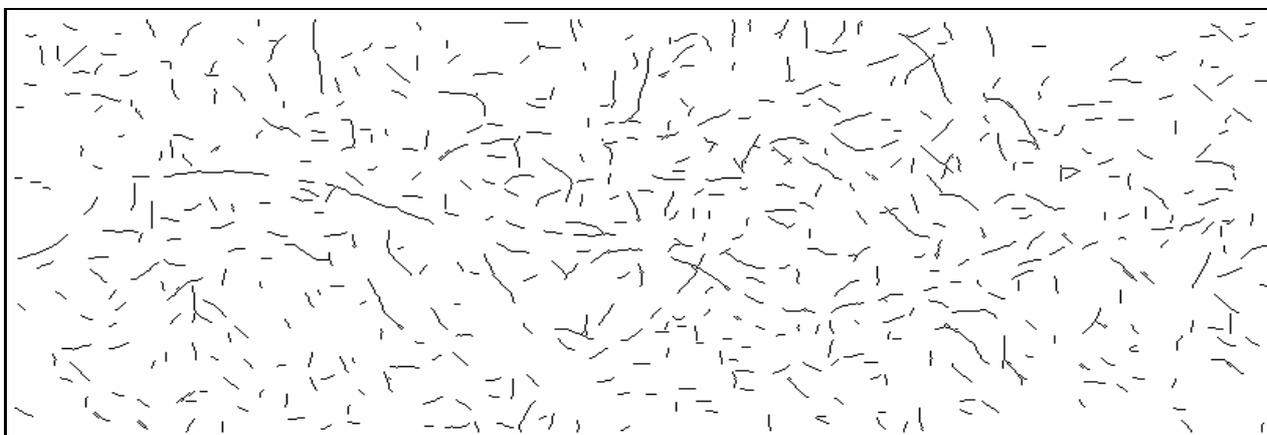
La probabilité  $p(D)$  ne dépendant pas de l'étiquetage  $L$ , il nous faut estimer  $p(L)$  et  $p(D|L)$ . La distribution conditionnelle des données connaissant  $L$ ,  $p(D|L)$ , est déduite d'une étape d'apprentissage sur des Obl connus et détectés par exemple manuellement. La probabilité a

2. Notons que des cycles de trois segments forment également une clique, mais le potentiel qui lui sera associé sera nul.

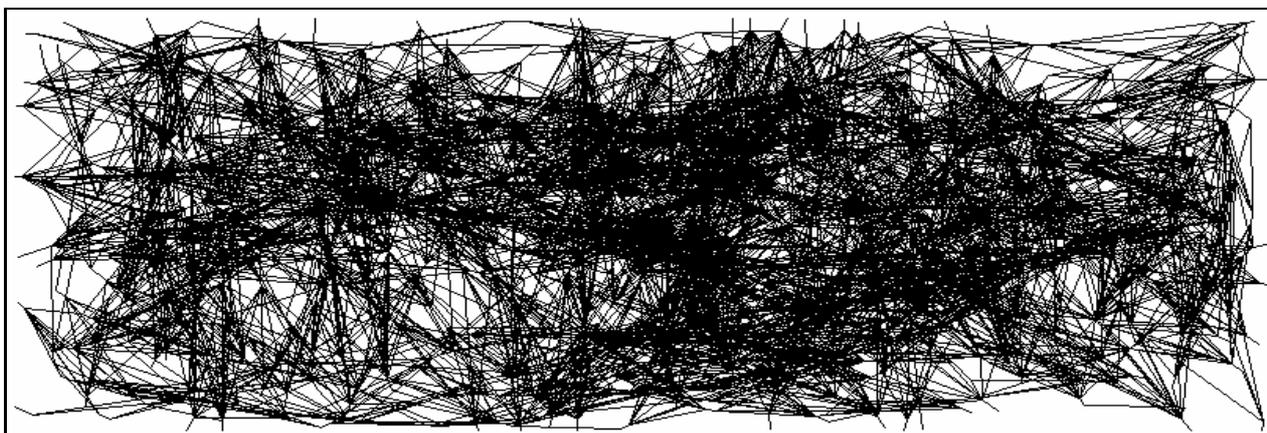
3. Dans toute la suite, une variable ou un champ (parfois abusivement appelé processus) aléatoire sera noté en majuscule, et une de ses valeurs ou réalisations en minuscule.



a. Image originale centrée sur Aix en Provence ©ESA .



b. Ensemble des 839 segments de  $S_d$  .



c. Ensemble des 8891 segments de  $S$  .

FIG. 3.3 – *Les étapes de la construction du graphe*

priori de l'étiquetage  $p(L)$ , est définie par un modèle markovien reposant sur notre connaissance a priori de l'Obl (cette modélisation est bien sûr différente qu'il s'agisse d'un Obl route ou d'un Obl fleuve).

### 3.3 Distributions conditionnelles, a priori, et a posteriori

En utilisant l'équivalence existant entre un champ de Markov et un champ de Gibbs, nous modélisons dans cette partie le processus d'étiquette  $L$  conditionnellement au champ des observations  $D$  comme un champ de Markov.

#### 3.3.1 Distribution conditionnelle du champ d'observations $p(D|L)$

Définissons d'abord le processus des observations. L'information contenue dans l'image d'origine pour la détection d'objets linéiques n'est pas la valeur radiométrique en un pixel, mais la réponse aux détecteurs de structures. Ayant limité la recherche des Obl aux segments de  $S$ , nous pouvons restreindre les observations à ces segments. Nous définissons donc l'observation  $D_i$  pour un segment  $i$  de direction  $\vec{d}$  de la façon suivante. En chaque pixel  $s$  du segment, sont calculées les réponses  $r_s$  et  $\rho_s$  aux détecteurs D1 et D2 appliqués dans la direction  $\vec{d}$ <sup>4</sup>. La région centrale du masque est définie le long du segment, quand les deux autres le sont de part et d'autre. Les deux réponses sont ensuite fusionnées en utilisant l'équation 2.7.

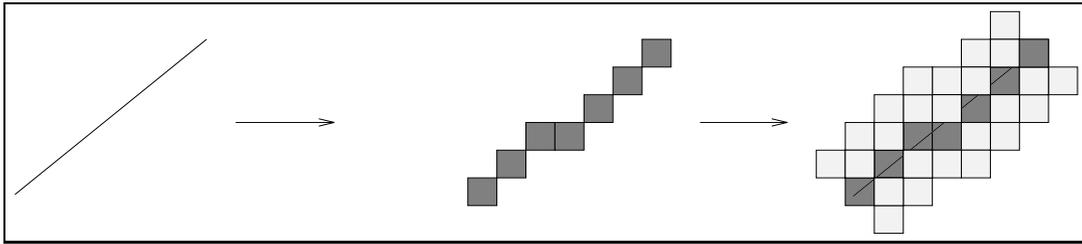


FIG. 3.4 – Calcul des observations

On peut ensuite définir l'observation  $D_i$  de plusieurs façons suivant l'application concernée, la démarche étant de nous appuyer sur les mesures faites sur des objets linéiques segmentés manuellement. On peut, par exemple, choisir la mesure moyenne calculée sur tous les pixels du segment, ou bien le pourcentage de pixels qui ont une mesure supérieure à un seuil (cela sera discuté au chapitre 4).

On considère donc le processus de mesure  $D = (D_1, D_2, \dots, D_N)$ , dont on observe une réalisation  $(d_1, d_2, \dots, d_N)$ , où  $d_i$  est la mesure calculée le long du segment  $i$ .

Avec l'hypothèse d'indépendance des segments, et en supposant que la distribution conditionnelle d'une observation en un segment ne dépende que de la connaissance du champ d'étiquettes en ce segment, nous obtenons :

$$p(D|L) = \prod_{i=1}^N p(D_i|L) = \prod_{i=1}^N p(D_i = d_i | L_i = l_i)$$

Ces hypothèses d'indépendance nous permettent donc d'exprimer  $p(D|L)$  sous une forme

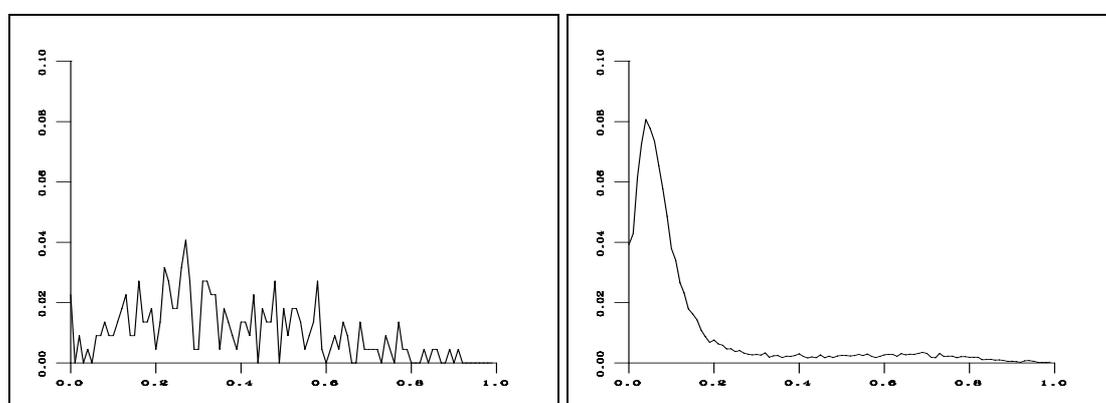
4. Notons qu'ici, contrairement au chapitre 2,  $\vec{d}$  n'est pas discrétisée.

énergétique fondée sur le potentiel d'un segment  $V(d_i|l_i)$ .

$$\begin{aligned} p(D|L) &\propto e^{(-\sum_{i=1}^N V(d_i|l_i))} \\ &\propto e^{-U(d|l)} \end{aligned}$$

en définissant  $U(d|l)$  comme la somme des potentiels des segments. Pour les estimer, nous cherchons donc à exprimer  $p(D_i|L_i)$ .  $D_i$  est une variable aléatoire pouvant prendre ses valeurs dans  $[0, 1]$ , et  $L_i$  dans  $\{0, 1\}$ . Ces densités de probabilités conditionnelles sont obtenues par apprentissage sur des segmentations manuelles. Elles dépendent, bien sûr, de l'objet linéaire qu'on cherche à détecter. Les potentiels  $V(d_i|l_i)$  en sont déduits en faisant des hypothèses de stationnarité et d'ergodicité.

Nous illustrons la démarche que nous avons suivie sur l'exemple de la détection des routes dans les images ROS.



a. Fréquences des observations sur des segments-routes détectés manuellement (approximant  $p(D|1)$ ).

b. Fréquence des observations sur des segments-non routes (approximant  $p(D|0)$ ).

FIG. 3.5 – Fréquences conditionnelles des observations sur une image des Pays-Bas.

La figure 3.5 montre les fréquences conditionnelles des données obtenues après une détection manuelle du réseau sur la région entourant Lelystad. Les segments "non route" sont ceux obtenus au sortir de la première étape, après suppression des segments appartenant aux routes détectées. D'une part, on constate que  $p(D|L = 1)$  est pratiquement uniforme (fig.3.5a), et que presque toutes les valeurs de mesures sont possibles le long d'une route. Cela est dû au fait que la visibilité de la route peut beaucoup varier en fonction de son environnement (présence de champs de faibles radiométrie, relief, recouvrement partiel par des constructions ou de la végétation...). D'autre part, on constate que sur  $S$  presque tous les segments "non route" ont une mesure inférieure à 0,2 (sur cette image), ce qui permet une discrimination facile (fig.3.5b)<sup>5</sup>.

Dans la pratique, et pour tous les graphes, il est difficile d'estimer les potentiels. En effet, on ne dispose que d'une réalisation de  $D|L$  (notre image, ou les données qu'on en extrait), et il faut de fortes hypothèses de stationnarité et d'ergodicité pour la majeure partie

5. Les distributions des réponses d'un détecteur de lignes sur le fond et sur les routes d'images SPOT données dans l'article récent de Geman et Jédyneck [Gema-96] ont des allures similaires.

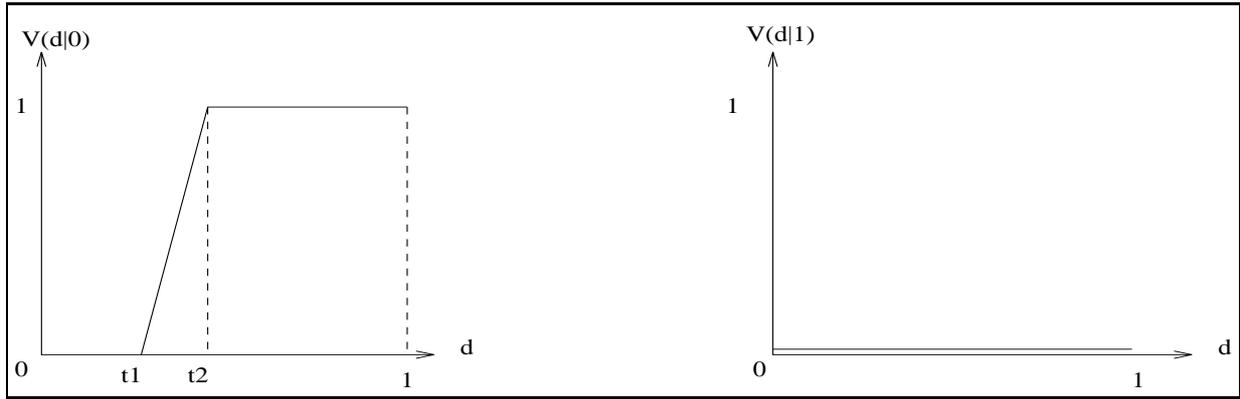


FIG. 3.6 – Potentiels linéaires par morceaux utilisés

des procédés d'estimation [Desc-93]. Des techniques relativement élaborées peuvent être utilisées comme un réseau de neurones entraîné sur une base d'apprentissage représentative [Kim-93]. Les potentiels ont ici été ajustés à la main, bien que déduits des observations précédentes, et des statistiques des détecteurs calculées dans la partie 2. Pour des raisons de simplicité, et parce qu'il est préférable pour le recuit simulé de travailler avec des potentiels bornés, nous les avons choisis linéaires par morceaux :

$$\begin{aligned}
 V(D_i = d_i | L_i = 0) &= 0 \text{ si } d_i < t_1 \\
 V(D_i = d_i | L_i = 0) &= \frac{d_i - t_1}{t_2 - t_1} \text{ si } t_1 < d_i < t_2 \\
 V(D_i = d_i | L_i = 0) &= 1 \text{ si } d_i > t_2 \\
 V(D_i = d_i | L_i = 1) &= 0 \quad \forall d_i
 \end{aligned}$$

Si nous voulons faire dériver les potentiels des densités de probabilités  $p(D_i | L_i)$ , il nous faut tenir compte de la contrainte de normalisation [Maru-95] :

$$\int_0^1 p(D_i = t | L_i = 1) dt = \int_0^1 \exp(-V(D_i = t | L_i = 1)) dt = 1$$

Le choix  $V(D_i = d_i | L_i = 1) = 0$  permet de remplir cette contrainte. Pour normaliser les potentiels correspondant à l'étiquette 0, nous remplaçons  $V(D_i = d_i | L_i = 0)$  par  $V(D_i = d_i | L_i = 0) + \log Z$ , où  $Z$  est une constante de normalisation définie par :

$$Z = \int_0^1 \exp(-V(D_i = t | L_i = 0)) dt$$

ce qui implique :

$$Z = t_1 + (1 - t_2) \frac{1}{e} - (t_2 - t_1) \left( \frac{1}{e} - 1 \right)$$

De plus, comme  $Z < 1$ ,  $\log Z < 0$ .

### 3.3.2 Probabilité a priori du champ d'étiquettes $p(L)$

Nous allons supposer ici que  $L$  est un processus markovien. Rappelons qu'un processus stochastique  $L$ , muni d'un système de voisinage  $\mathcal{V}$ , est un champ de Markov si :

$$\forall l \in \Omega, p(L = l) > 0$$

$$p(L_i = l_i | L_j = l_j, j \neq i) = p(L_i = l_i | L_j = l_j, j \in \mathcal{V}_i)$$

L'interprétation d'un Obl s'effectuant sur un voisinage limité (à l'échelle d'un segment), nous pouvons légitimement supposer  $L$  markovien sur l'espace des états  $\Omega$ . L'équivalence champ de Markov-champ de Gibbs (théorème de Hammersley-Clifford) nous permet ensuite d'écrire que :

$$p(L = l) = \frac{e^{-U(l)}}{Z_n}$$

$$U(l) = \sum_{c \in \mathcal{C}l} V_c(l)$$

où  $\mathcal{C}l$  représente l'ensemble des cliques de  $G$  et  $Z_n$  une constante de normalisation. Il nous reste ici à choisir les potentiels des cliques et donc à exprimer les connaissances a priori que nous voulons intégrer dans notre modèle. Généralement lorsque l'on utilise un contexte markovien en restauration ou segmentation d'images, le modèle d'Ising (ou sa version maire, le modèle de Potts) est utilisé. Cela revient en définitive à modéliser la connaissance a priori : "la longueur des contours doit être minimale" [Desc-95].

Dans le cas de la détection de réseau, là encore, tout dépendra de l'application choisie, la modélisation d'un cours d'eau étant par exemple très différente de celle d'une route.

Comme précédemment, nous prenons le cas du réseau routier pour illustrer la définition de l'énergie.

Nous avons choisi de modéliser ici les connaissances suivantes :

- (i) les routes sont longues et, dans l'absolu, elles ne s'arrêtent pas ;
- (ii) elles ont une courbure relativement faible ;
- (iii) un segment de route est plus souvent connecté en une extrémité à un unique segment de route qu'à plusieurs.

En résumé, une route idéale sera pour nous une succession infinie (au moins un nombre suffisant) de segments, avec une courbure faible. La troisième condition n'exclut pas les carrefours, mais leur donne une probabilité faible (celle-ci sera d'autant plus faible que le nombre de routes partant du carrefour sera élevé). Notons ici qu'il s'agit des "vrais" carrefours et qu'une configuration où deux routes se croisent (ou se superposent) n'est aucunement pénalisée (fig.3.7). Cette condition est nécessaire pour éviter les connexions multiples de segments le long d'une même route. A la résolution où nous sommes, les embranchements restent relativement rares.

Ces a priori s'expriment dans les potentiels sous la forme suivante. Rappelons qu'une clique de  $G$  est un ensemble de segments ayant une extrémité en commun ou un segment isolé. Nous choisissons des potentiels nuls pour toutes les cliques, sauf pour les cliques d'ordre maximal constituées par des segments ayant une même extrémité en commun<sup>6</sup>,

6. L'ordre maximal varie suivant l'extrémité considérée.

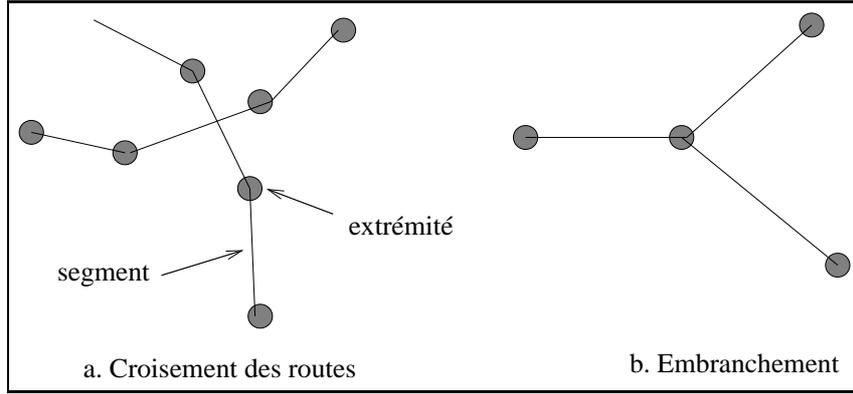


FIG. 3.7 – Croisements et embranchements dans la représentation image

dont nous définissons le potentiel comme suit :

$$\begin{aligned} \forall s_i \in c, l_i = 0 &\Rightarrow V_c(l) = 0 \\ \exists! s_i \in c / l_i = 1 &\Rightarrow V_c(l) = K_e - K_{\mathcal{L}} \mathcal{L}_i \\ \exists!(s_i, s_j) \in c^2 / l_i = l_j = 1, \mathcal{R}_{ij} > \frac{\pi}{2} &\Rightarrow V_c(l) = -K_{\mathcal{L}}(\mathcal{L}_i + \mathcal{L}_j) + K_c \sin \mathcal{R}_{ij} \end{aligned}$$

dans tous les autres cas  $V_c(l) = K_i \sum_{i/s_i \in c} l_i$

Tous les paramètres que nous avons introduits sont reliés de façon simple aux trois conditions précédemment mentionnées. En choisissant  $K_e > 0$  et  $K_{\mathcal{L}} > 0$ , nous remplissons la condition (i) et favorisons les longues chaînes de segments (fig. 3.8). A la place de la longueur  $\mathcal{L}_i$ , nous utilisons une longueur normalisée  $\frac{\mathcal{L}_i}{\mathcal{L}_{max}} \in [0, 1]$  pour pouvoir maîtriser les variations énergétiques (on continuera à noter  $\mathcal{L}_i$  dans toute la suite). Le choix de  $K_c > 0$  pénalise les configurations des routes avec une forte courbure, ce qui correspond à la condition (ii), tandis que  $K_i > 0$  désavantage les carrefours (iii). Le choix de ces paramètres est traité dans la suite.

Sans le champ d'observations, le résultat de l'étiquetage du graphe est constitué de longues chaînes connectant les segments avec une faible courbure (fig.3.10).

### 3.3.3 Probabilité a posteriori du champ d'étiquettes $p(L|D)$

Nous avons vu qu'on pouvait faire correspondre aux distributions  $p(D|L)$  et  $p(L)$  des distributions de Gibbs d'énergie  $U(d|l)$  et  $U(l)$ . La probabilité du champ total est donc équivalente à une distribution de Gibbs d'énergie  $U(d|l) + U(l)$ . Il s'agit donc d'un champ de Markov défini sur  $G$  et à valeurs dans le même espace  $\Omega$  que le champ d'étiquettes  $L$ . L'énergie globale s'écrit :

$$U(l|d) = \sum_i V(d_i|l_i) + \sum_{c \in \mathcal{C}l} V_c(l)$$

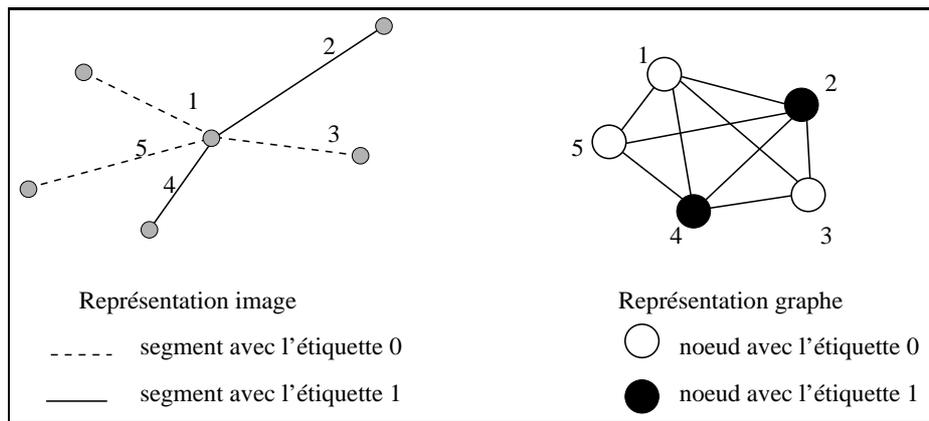


FIG. 3.8 – Exemple d’une configuration favorable pour une route (2 segments avec l’étiquette 1 connectés à la même extrémité) : à gauche dans la représentation de l’image, à droite dans la représentation du graphe

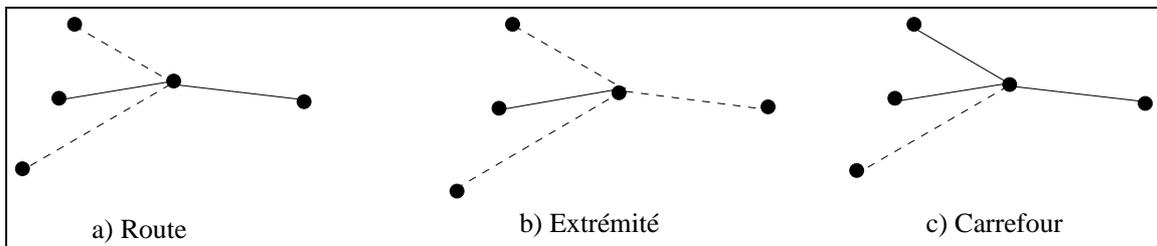


FIG. 3.9 – Exemples de configurations dans la représentation image (en pointillés : label à 0, en trait plein à 1)

Les potentiels intervenant sont ceux définis précédemment dans la distribution conditionnelle pour les cliques d’ordre 1, et dans la probabilité a priori pour les cliques de plus grand ordre (et sont nuls sinon).

L’énergie  $U(d|l)$  s’interprète comme un terme d’attache aux données pour le champ total qui empêche la solution de s’éloigner trop fortement de la réalité de l’image (ce qui corres-

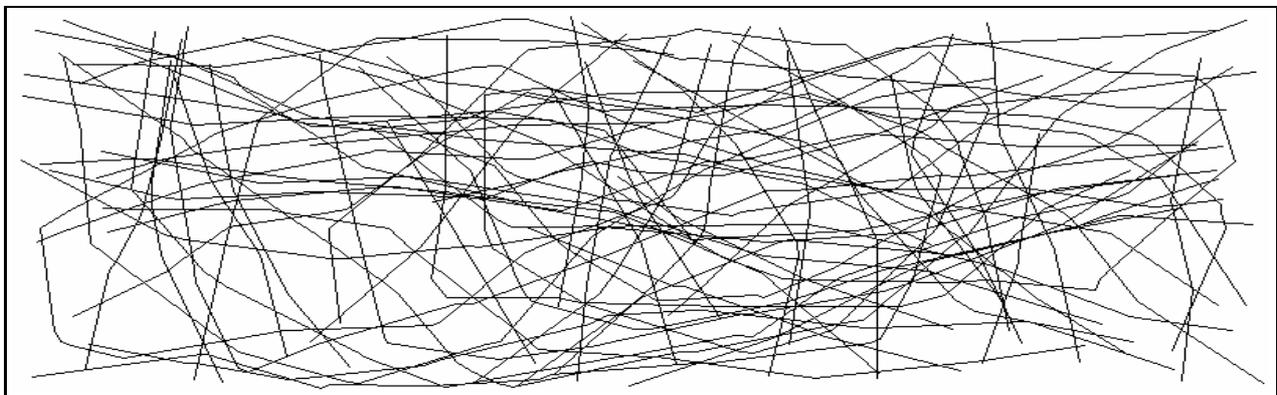


FIG. 3.10 – Résultat de la détection sans attache aux données sur l’image d’Aix

pondrait en physique au champ externe). L'énergie  $U(l)$  correspond à un terme contextuel qui contraint la solution, permettant de tenir compte de connaissances a priori.

Par ailleurs, pour prendre en compte également la longueur des segments dans le terme d'attache aux données et attribuer plus de poids à celui-ci dans le cas de longs segments, nous utilisons non pas  $V(d_i|l_i) + \log Z$  mais  $\mathcal{L}_i V(d_i|l_i) + \log Z$ . La constante de normalisation  $Z$  dépend alors de  $\mathcal{L}_i$ . Pour simplifier, nous noterons simplement  $Z$  dans la suite.

## 3.4 Minimisation de l'énergie

### 3.4.1 Remarques sur le recuit simulé

La formulation énergétique du champ de Markov total permet de ramener la recherche du maximum a posteriori à une minimisation de l'énergie. L'énergie correspondant à notre modèle Markovien étant non-convexe, des techniques adaptées doivent être utilisées. Nous avons choisi ici d'utiliser un recuit simulé. Si les résultats sont souvent spectaculaires (compte tenu des initialisations totalement aléatoires), ils sont néanmoins intimement liés à la forme des paysages énergétiques. Le résultat fondamental de Geman et Geman [Gema-84] sur les propriétés de convergence de l'algorithme est en effet lié à des contraintes de décroissance en température très contraignantes, et en pratique inutilisables. Ainsi, lorsque des décroissances plus rapides (géométriques par exemple) de la température sont utilisées, le minimum global n'est pas nécessairement atteint et l'algorithme peut rester bloqué dans un minimum local.

Des difficultés apparaissent également lors de l'introduction de contraintes globales sur le champ d'étiquettes  $L$  ; citons des contraintes topologiques ou d'adjacence entre les classes par exemple, ou bien encore des termes supplémentaires visant à obtenir une taille ou une surface donnée pour l'une d'elles. Nous sortons alors du cadre markovien puisque une grande partie des configurations est interdite et qu'elles ont donc une probabilité nulle. On ne considère dans ce cas la minimisation énergétique que sur un sous-ensemble de l'espace d'états  $\Omega$ . Une des solutions peut consister alors à passer par la minimisation de sous-butts énergétiques intermédiaires, obtenus en modifiant la forme de l'énergie par l'ajout ou la suppression de certains potentiels [Mang-95b].

Ceci dit, dans certains cas pourtant markoviens, il peut se révéler également difficile d'atteindre un minimum global, notamment lorsque le paysage énergétique présente une multitude de minima globaux. C'est le cas du "chien-modèle" de Descombes [Desc-95], dont la construction doit préserver les lignes et les contours de l'image. Une solution proposée par Mangin ([Mang-95a], chapitre 3) est de choisir une topologie adaptée au paysage énergétique pour l'exploration du recuit, et, par exemple, de remplacer le parcours séquentiel des sites du recuit simulé par le parcours d'une composante connexe de sites.

### 3.4.2 Recuit simulé dédié au graphe des segments

Une première implantation du recuit simulé, correspondant à l'algorithme de Metropolis, a été effectuée avec un parcours aléatoire des sommets du graphe. De façon classique,

le changement d'état n'était considéré que pour le seul segment choisi, et effectué avec la probabilité  $p = \min(1, e^{-\frac{\Delta U}{T}})$ , en notant  $\Delta U$  la variation énergétique associée au changement d'état du segment. Les résultats obtenus se sont révélés particulièrement instables, les étiquetages correspondant à des tirages aléatoires différents lors du recuit simulé étant distincts. Ceci est dû à la présence de multiples minima locaux, et au non respect de la loi de décroissance logarithmique de la température [Gema-84] [Laar-87] (on a pris une décroissance géométrique en 0.99).

La solution proposée par Mangin et précédemment citée a donc été implantée. Elle consiste à considérer un changement d'état non plus pour un sommet, mais pour un ensemble de sommets adjacents. Nous avons pris ici des triplets de segments adjacents (un des sommets est tiré aléatoirement, puis deux sommets parmi les sommets adjacents) et nous avons calculé les huit variations énergétiques correspondantes aux huit changements d'état possibles. L'échantillonneur de Gibbs est ensuite appliqué, c'est à dire que la transition entre deux états se fait selon un tirage aléatoire respectant la loi de probabilité sur l'ensemble des huit transitions possibles.

Cependant, la lenteur de cet algorithme le rend difficile d'utilisation sur de grandes images. Nous proposons dans ce cas de conserver le principe des triplets (qui semble être la clé de la convergence), et d'utiliser un algorithme plus rapide : algorithme de Metropolis, ou même ICM en utilisant une "bonne" initialisation (par exemple étiqueter à 1 les segments de  $S_d$  détectés par l'étape bas-niveau, et à 0 les autres), à la place de l'échantillonneur de Gibbs. Néanmoins, les résultats sont dans ce cas instables, bien que proches du minimum global.

Notons également que la finesse des structures recherchées rend souvent mal adapté l'emploi de méthodes multi-échelles [Pere-93] [Kato-94] [Graf-95] où l'initialisation est généralement donnée par le résultat obtenu à une résolution plus grossière (la plupart des routes ne sont visibles qu'à pleine résolution). Par ailleurs, la structure très spécifique du graphe utilisé (non planaire et à topologie variable) ne permet pas une transposition simple des techniques multi-grilles pour lesquelles des résultats théoriques ont été obtenus [Pere-93].

### 3.5 Analyse de l'influence des paramètres

La difficulté principale rencontrée lors de l'utilisation de champs markoviens réside dans le choix des hyper-paramètres de la distribution, choix qui définit l'importance des différents types d'interactions. Nous avons vu que les contraintes que nous cherchons à intégrer imposent les signes des paramètres  $K_e$ ,  $K_L$ , et  $K_c$ . Ici, nous nous proposons d'établir des intervalles de variation pour les paramètres en considérant des configurations particulières, les raisonnements étant tenus sur l'exemple de la détection des routes. Cette méthode repose sur le principe des boîtes qualitatives d'Azencott [Chal-88] [Azen-92b] [Graf-93] [Urag-96].

Une configuration qui nous sera particulièrement utile est la configuration "nulle" correspondant à l'absence de structure linéaire (toutes les étiquettes des segments sont à 0).

Ces configurations particulières sont les suivantes :

- ◇ Premièrement, nous ne voulons pas connecter systématiquement deux chaînes de segments (figure 3.11a). Or, la variation énergétique entre la configuration non connectée

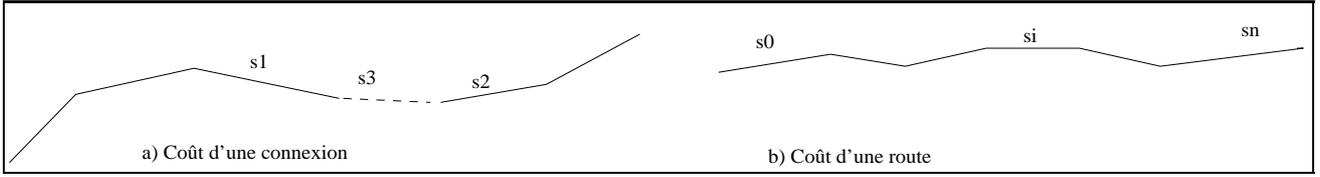


FIG. 3.11 – Exemples de configurations (en pointillés : label à 0, en trait plein à 1)

et celle connectée est :

$$\Delta U = -2K_{\mathcal{L}}\mathcal{L}_3 + K_c(\sin \mathcal{R}_{13} + \sin \mathcal{R}_{23}) - 2K_e + \mathcal{L}_3(V(d_3|1) - V(d_3|0))$$

Plaçons nous dans le cas où tous les segments sont alignés, et où le segment intermédiaire est un grand segment ( $\mathcal{L}_3 = 1$ ) de mesure trop faible pour appartenir à une route ( $V(d_3|0) = \log Z$ ). Puisque nous ne voulons pas le connecter, nous déduisons de la condition  $\Delta U > 0$  la contrainte suivante :

$$K_e + K_{\mathcal{L}} < \frac{-\log Z}{2} \text{ avec } \log Z < 0$$

Ce choix est nécessaire pour limiter le pouvoir de connexion dans des conditions défavorables.

- ◇ Deuxièmement, en comparant l'énergie de la configuration "nulle" et celle d'une structure détectée sur un ensemble de segments (fig.3.11b), nous pouvons déduire une relation entre la longueur totale de la structure linéaire et le couple de paramètres ( $K_i, K_{\mathcal{L}}$ ). En effet, la variation énergétique entre les deux configurations est :

$$\Delta U = 2K_e - 2K_{\mathcal{L}} \sum_{j=0}^n \mathcal{L}_j + K_c \left( \sum_{j=0}^{n-1} \sin \mathcal{R}_{j(j+1)} \right) + \sum_{j=0}^n \mathcal{L}_j (V(d_j|1) - V(d_j|0))$$

Prenons le cas où il existe réellement une structure linéaire à détecter ( $\forall i \ V(d_i|0) = 1 + \log Z$ ) dont tous les segments sont parfaitement alignés ( $\forall j \ \sin \mathcal{R}_{j(j+1)} = 0$ ). Sous ces conditions, pour être moins énergétique que la configuration "nulle" où tous les segments sont à 0, la contrainte suivante doit être remplie :

$$2K_e - 2K_{\mathcal{L}} \sum_{j=0}^n \mathcal{L}_j - (1 + \log Z) \sum_{j=0}^n \mathcal{L}_j < 0$$

En notant  $\mathcal{L}_t$  la longueur totale de la structure, nous obtenons :

$$\mathcal{L}_t > \frac{2K_e}{2K_{\mathcal{L}} + 1 + \log Z}$$

Plus le rapport  $\frac{2K_e}{2K_{\mathcal{L}} + 1 + \log Z}$  est grand, plus longue doit être la route pour être acceptée.

D'autres configurations peuvent être étudiées, et d'autres contraintes introduites (par exemple, ne jamais conserver un segment étiqueté Obl qui ne soit pas au moins connecté à un

autre). Il peut arriver que le paramètre  $K_{\mathcal{L}}$  doive être positif. Cette situation n'est cependant pas contradictoire avec la contrainte "longues chaînes de segments" puisque  $K_e$ , qui pénalise les extrémités, agit également dans ce sens.

Le réglage de  $K_c$  est relativement simple ; plus ce paramètre augmente, plus les structures détectées seront rectilignes.

Quant à  $K_i$ , son rôle est de limiter les connexions multiples aux extrémités des segments. Nous choisissons en pratique sa valeur du même ordre que  $K_e$  et  $K_{\mathcal{L}}$ .

Nous illustrons les analyses précédentes sur une petite image centrée sur la ville d'Aix (figure 3.3a).

La configuration initiale sur laquelle débute le recuit simulé est totalement aléatoire et, à titre de comparaison, l'énergie de cette configuration est de 68 857. La température initiale est prise à 4, et  $\mathcal{L}_{max}$  est égale à 100 pixels.

Les deux premières images (fig.3.12a et fig.3.12b) illustrent l'influence des paramètres  $K_e$  et  $K_{\mathcal{L}}$ . Les couples sont tels que  $\frac{K_e}{K_{\mathcal{L}}}$  augmente. Par conséquent, les routes conservées sont de plus en plus longues ou ont des segments avec des mesures plus élevées. En contrepartie, de moins en moins de routes sont détectées. Les seuils sur la mesure sont constants et égaux à 0,2 et 0,3.

La troisième image 3.12c illustre l'influence des seuils  $t_1$  et  $t_2$  intervenant dans la définition du potentiel  $V(D_i|0)$ . En comparant les figures 3.12b et 3.12c, on constate que la baisse du seuil  $t_2$  entraîne une augmentation des segments détectés.

### 3.6 Repositionnement des segments

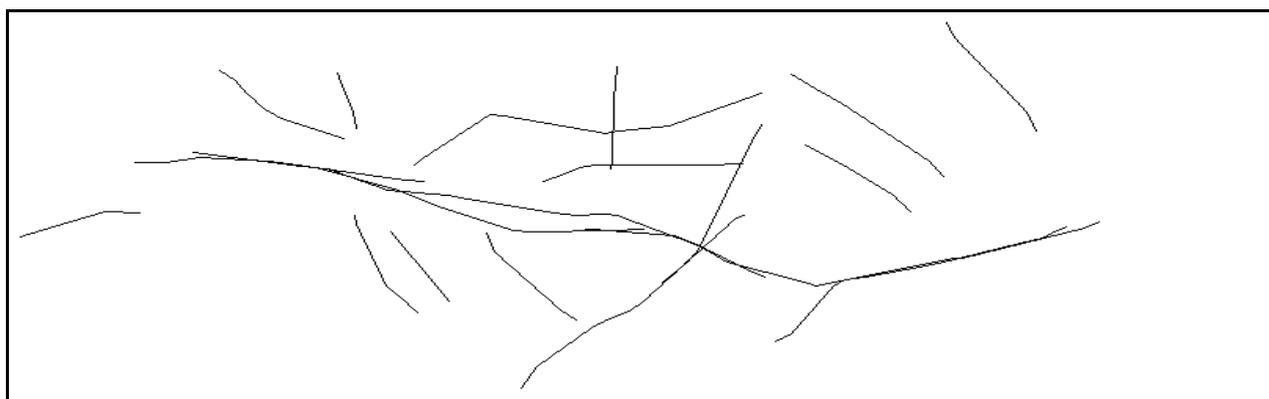
L'étape précédente crée des liaisons entre portions de structures linéaires sous forme de segments, mais ces segments ne sont pas toujours bien placés au niveau du pixel. Pour repositionner les segments résultats, une méthode de snakes très simple a été utilisée.

Rappelons que l'idée originelle de Kass, Witkin et Terzopoulos [Kass-88] est de faire évoluer une courbe vers le contour (ou ligne extrême) le plus proche sous l'effet de forces créées par l'image ou externes, et en tenant compte de contraintes de régularisation sur la courbe (forces internes). D'une façon plus formelle, il s'agit de déduire la courbe minimisant l'énergie :

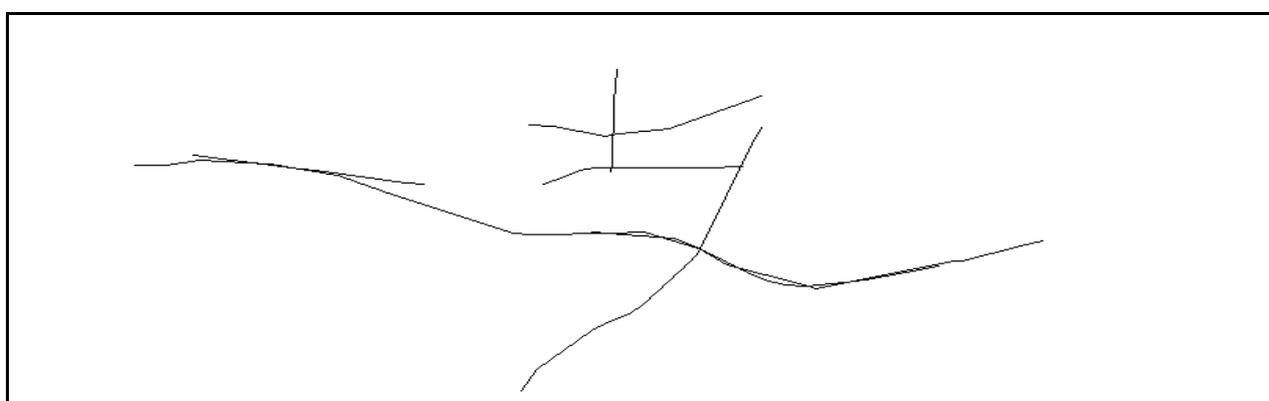
$$E_{snake} = \int_0^1 E_{int}(v(s)) + E_{ext}(v(s)) ds$$

où  $s$  est un paramétrage de la courbe. L'énergie interne est généralement prise comme  $E_{int} = \alpha(s)|v'(s)|^2 + \beta(s)|v''(s)|^2$  ; ce terme contrôle la régularité de la courbe en influençant d'une part sa longueur, d'autre part sa courbure. L'énergie externe dépend de la structure qu'on cherche à mettre en évidence. Si on considère, par exemple, le cas de la détection des lignes sombres, on aura :  $E_{ext} = \int_0^1 I(v(s))ds$ , où  $I$  est l'intensité de l'image. Les équations d'Euler et l'approximation des dérivées par des méthodes de différences finies permettent de se ramener à une écriture matricielle avec l'hypothèse de constance des forces pendant une iteration :

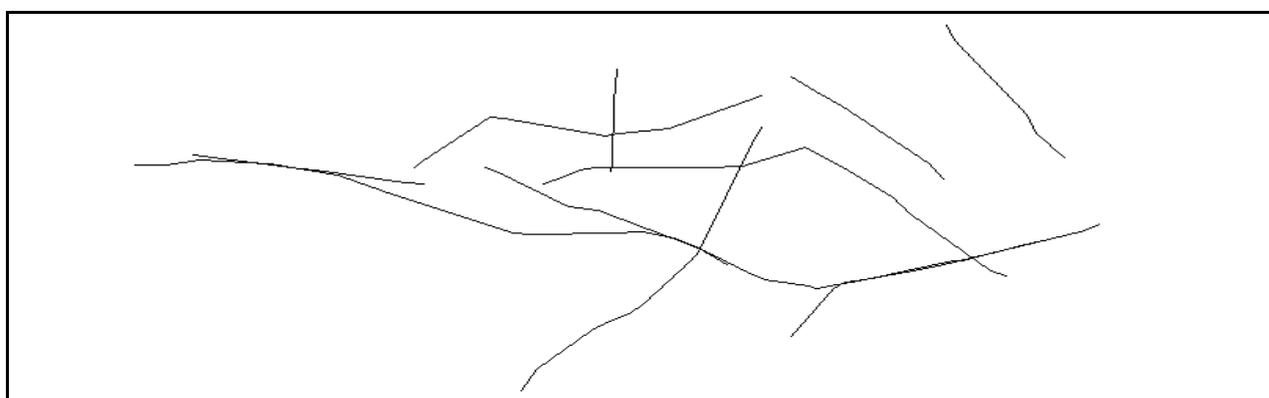
$$(A + \gamma I)V_t = \gamma V_{t-1} + \frac{\delta f}{\delta v}(V_{t-1})$$



a.  $t_1 = 0.2, t_2 = 0.3, \log Z = -0.65, K_e = 0.1, K_{\mathcal{L}} = 0.2, K_c = 0.3, K_i = 0.2.$



b.  $t_1 = 0.2, t_2 = 0.3, \log Z = -0.65, K_e = 0.17, K_{\mathcal{L}} = 0.13, K_c = 0.3, K_i = 0.2.$



c.  $t_1 = 0.2, t_2 = 0.25, \log Z = -0.67, K_e = 0.17, K_{\mathcal{L}} = 0.13, K_c = 0.3, K_i = 0.2.$

FIG. 3.12 – Influence des paramètres  $K_e$  et  $K_{\mathcal{L}}$ , et des seuils  $t_1$  et  $t_2$ .

où  $V_t$  est un vecteur représentant l'ensemble des points du snake à l'instant  $t$ ,  $f(v) = |I(v)|^2$  par exemple pour les lignes sombres,  $\gamma$  joue en quelque sorte le rôle de "poids de la courbe". On pourra se référer aux articles et thèses [Berg-91], [Cohé-92], [Nast-94], [Neue-95].

La méthode originelle des contours actifs est assez longue et ne se justifie pas lorsque l'on souhaite juste déformer localement le contour trouvé. Nous adopterons un modèle simplifié inspiré du travail de P. Guérin [Guer-93]. L'initialisation du contour actif est pour nous une chaîne de segments détectée au sortir du recuit simulé (on considérera donc autant de

contours actifs que de chaînes).

Pour trouver la position de la courbe minimisant  $E = E_{int} + E_{ext}$ , nous découpons la configuration initiale en segments élémentaires, et nous fixons les extrémités de la chaîne. Dès lors, chaque sommet intermédiaire sera susceptible de se déplacer dans une zone de recherche définie (figure 3.13b). La courbe pouvant présenter des discontinuités importantes, l'évaluation de la tangente en un point se fait par convolution avec la dérivée d'une gaussienne tronquée [Lowe-89]. Les points situés sur la normale à la courbe lissée en un sommet constituent sa zone de déplacement possible. La nouvelle position du sommet est celle qui minimise une énergie  $E$ .

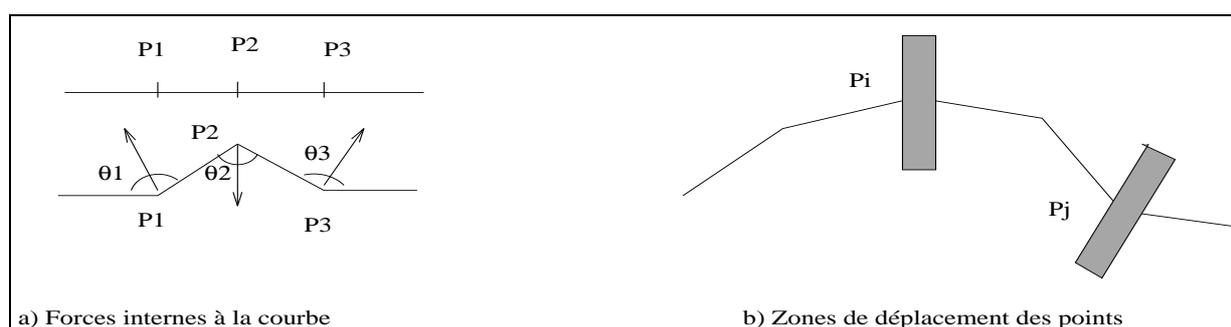


FIG. 3.13 – *Contours actifs simplifiés*

L'énergie externe est  $E_{ext} = I$ , où, lorsque nous cherchons à détecter les lignes sombres de l'image,  $I$  est l'intensité ( $-I$  dans le cas des structures brillantes). Quant à l'énergie interne, elle exprime des forces de rappel qui s'exercent sur un point de la courbe lorsque l'on tente de le déplacer. Si nous simplifions la situation en supposant que seuls les deux points adjacents sont concernés, nous pouvons écrire (figure 3.13a) :

$$E_{int} = \sum_{i=1}^3 \frac{c_i}{2} (\pi - \theta_i)^2$$

Pour éviter des phénomènes d' "entraînement" entre sommets, leur parcours est effectué aléatoirement. Les paramètres  $c_i$  permettent d'influer sur la rigidité de la courbe.

De façon expérimentale, on a choisi :  $c_i = 0, 1$  et la longueur des segments élémentaires à cinq pixels. La figure 3.14 montre un exemple d'application.

### 3.7 Conclusion

Nous avons proposé dans ce chapitre une méthode originale de détection de réseaux de structures linéaires. S'appuyant sur un ensemble de segments détectés par une étape de bas-niveau, cette technique markovienne est une méthode de connexion puissante qui permet de tenir compte de l'image, mais aussi d'une modélisation du réseau qu'on cherche à détecter.

L'originalité des sites choisis pour travailler, les segments, est paradoxalement une des richesses et des limites de cette méthode : une des richesses d'abord, puisqu'elle permet de connecter des segments éloignés, ce que ne permettent pas les méthodes markoviennes de

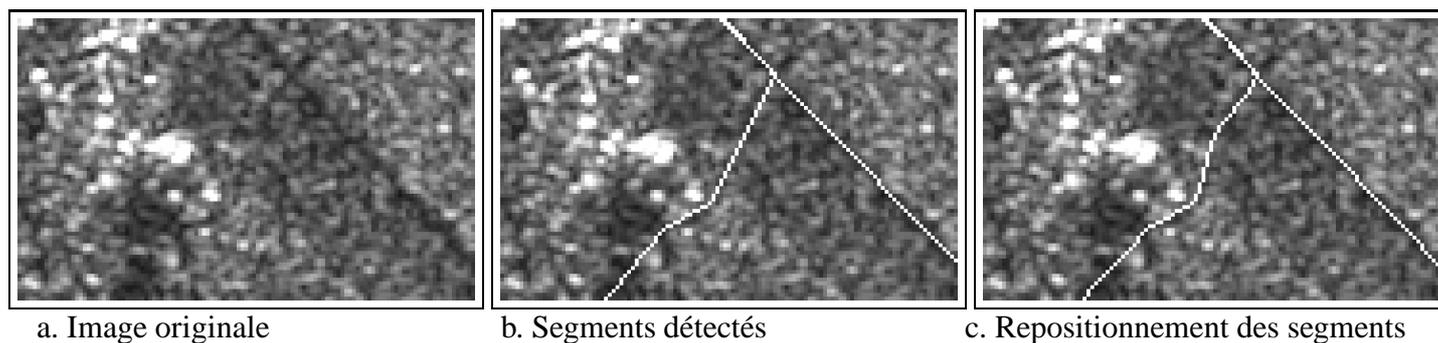


FIG. 3.14 – Application des contours actifs simplifiés.

fermeture travaillant sur des sites pixels ; une des limites aussi, en l'état actuel des choses, puisque notre hypothèse fondamentale (le graphe construit contient le réseau cherché) peut très bien être mise en défaut, par exemple si une connexion manquante fait une boucle importante.

Le chapitre suivant illustrera cette technique sur deux applications radar ERS-1, la détection du réseau routier et celle du réseau hydrographique. Bien que développée pour les images radar, cette technique markovienne de connexion reste cependant très générale et a pu être adaptée à d'autres formes de réseaux et d'autres sources de données [Mait-96].

Par ailleurs, nous pensons que la démarche qui a été adoptée dans ce chapitre est générique et pourrait être appliquée à d'autres objets, comme des bâtiments par exemple. La seule véritable contrainte est de pouvoir modéliser localement les relations entre les primitives utilisées. Un des problèmes susceptibles de se poser alors, est le choix des paramètres intervenant dans le modèle contextuel. L'étude qui a pu être effectuée ici à l'aide des boîtes qualitatives d'Azencott [Azen-92b] n'est pas nécessairement reproductible dans le cas d'objets plus complexes. Nous pensons qu'une solution peut être apportée par un apprentissage à l'aide de réseaux de neurones [Kim-93].

---

## Chapitre 4

### Applications

# Réseau routier, hydrographique, et zones de relief

*Cette partie présente trois applications utilisant les méthodes locale et globale que nous avons décrites dans les chapitres 2 et 3. La première application est la détection des axes principaux du réseau routier. Nous précisons tout d'abord les paramètres utilisés et abordons certains aspects pratiques. Plusieurs résultats sur des images variées illustrent ensuite les performances et les limites de la méthode. La deuxième application, proche de la première, est la détection du réseau hydrographique avec une analyse multi-échelles. Les connaissances a priori intervenant dans la méthode de connexion markovienne doivent dans ce cas être adaptées. Quant à la troisième application, il s'agit de situer les zones de relief particulièrement marqué en détectant les structures linéaires brillantes et en les regroupant selon des critères directionnels et de proximité.*

## 4.1 La détection du réseau routier

### 4.1.1 Intérêt et objectif

De multiples applications de télédétection (le recalage d'images multi-sources, la mise à jour de cartes, la navigation automatique...) nécessitent la détection du réseau routier [Lebe-90] [Cave-92]. De nombreux travaux permettent aujourd'hui son extraction automatique ou quasi-automatique sur les images satellitaires optiques à haute résolution (images SPOT panchromatiques à une résolution de 10 m) [Merl-96] [Gema-96], et aériennes à très haute résolution (50 à 100 cm) [McKeo-88] [Rusk-95] [Barz-96].

En revanche, sur les images radar, et en particulier sur les images radar satellitaires, les méthodes proposées sont loin d'obtenir des résultats aussi satisfaisants [Welc-88]. Nous recensons ici quelques-unes des méthodes de détection de lignes appliquées aux images radar. Clairement, les détecteurs locaux sont insuffisants et des informations globales de haut niveau doivent être utilisées.

La transformation de Hough [Duda-72] éventuellement "randomisée" [McLa-96], qui permet de rechercher des courbes paramétriques (droites ou cercles par exemple) dans une image a connu un engouement certain [Wood-85] [Queg-86] [Skin-87] [Hend-88b] [Gree-93]. Les seuils théoriques dans l'espace des paramètres peuvent être calculés en fonction de la probabilité de fausse alarme admise et de la longueur des courbes cherchées [Skin-87] [Hend-88]. Néanmoins, si les résultats sont encourageants [Skin-87] vu la difficulté des images -aéroporté en 1-vue-, l'application d'une telle méthode reste limitée [Wood-85], notamment par la paramétrisation qui restreint souvent en pratique la recherche à des segments de droite.

La programmation dynamique pour minimiser une fonction de coût global, après ses succès en imagerie optique avec l'algorithme de Fischler [Fisc-81] et ses extensions [Merl-93] [Merl-96], a également été appliquée. Pour détecter des routes claires, Wood [Wood-85] utilise un coût calculé sur l'intensité et la courbure, les points de départ étant sélectionnés comme particulièrement brillants. Samadani and Vesecky [Sama-90] proposent de minimiser un critère MAP, en parcourant l'espace à partir d'un pixel central par des carrés de taille croissante. La détection nécessite la connaissance d'un pixel de départ à partir duquel s'effectue la propagation.

Plus récemment, Hellwich *et al.* [Hell-96] se sont placés dans un cadre bayésien pour détecter des lignes. Un champ de Markov est défini en utilisant des informations a priori sur leur continuité et donc les relations de voisinage entre les pixels qui en résultent. Nous avons dans un premier temps adopté une démarche relativement similaire, qui a été utilisée (quoique sous une forme plus simple que dans [Hell-96]) pour la détection des ruptures de continuités d'un interférogramme [Tupi-96c]. Malheureusement, dans le cas d'images satellitales, une telle technique ne permet d'obtenir que des petits morceaux de routes déconnectés, alors que nous cherchons plutôt un découpage approximatif du paysage.

Les méthodes de "traking", qui sont souvent utilisées en imagerie SPOT [Gema-96], ont également été envisagées en imagerie radar [Jacq-97].

Citons aussi l'approche très intéressante de Regazzoni *et al.* pour la détection des contours en imagerie radar [Ardu-92] [Rega-94] [Rega-94b] [Rega-95]. Un champ markovien hiérarchique à trois niveaux, permettant d'intégrer simultanément des contraintes locales et globales, est défini : le premier niveau correspond à l'observation (l'image radar), le second à l'intensité restaurée et au processus bord, et le troisième à un ensemble de segments de droite. Un processus itératif, faisant collaborer les trois niveaux permet de réaliser la détection (le troisième niveau, qui correspond à la connaissance globale, est mis à jour en appliquant une transformée de Hough à une configuration donnée du deuxième niveau). Cependant les relations intervenant à ce troisième niveau sur les segments restent relativement simples, et l'injection des connaissances exprimées dans le chapitre 3 rendrait le processus très complexe et très long à gérer.

En réalité, les outils décrits dans les deux chapitres précédents sont nés du besoin impérieux de développer une méthode spécifique à l'objectif que nous avons. Nous cherchons à obtenir, à partir d'une image radar satellitale, une carte grossière du réseau routier nous procurant une information globale. L'utilisation d'un graphe de segments (chap.3) s'appuie sur le fait que toute méthode au niveau des pixels serait difficilement capable de franchir les

trous, parfois larges, où la route disparaît localement. Nous avons donc adapté les primitives à l'échelle du problème et choisi de travailler sur des segments de routes.

Nous nous proposons donc ici de détecter les axes principaux du réseau routier. La résolution des images radars ERS-1, JERS-1, SIR-C/X-SAR ou RADARSAT, de l'ordre de la dizaine de mètres, est suffisamment précise pour permettre la discrimination des routes principales lorsque le relief n'est pas prédominant. Nous avons choisi de nous limiter à la détection des routes dont la largeur varie de 1 à 5 pixels, ce qui correspond à une emprise au sol inférieure à 62,5 m à la résolution où nous sommes. Cela constitue la majeure partie du réseau routier, à l'exception des autoroutes avec un grand nombre de voies. Les techniques que nous utilisons sont celles dédiées aux réseaux fins (chapitre 2), où la notion primordiale est celle de structure linéaire.

De plus, conformément à notre objectif général d'interprétation quasi-automatique du paysage, nous nous sommes efforcés de développer une méthode de détection ne nécessitant pas d'initialisation manuelle par un opérateur et un réglage des paramètres simple. Ainsi, si certains paramètres restent à donner, les études théoriques des chapitres 2 et 3 permettent de restreindre les intervalles de choix. L'ensemble des processus procure, à partir de l'image, une carte des routes détectées.

Conformément aux étapes précédentes, la méthode que nous proposons se décompose en deux grandes étapes. La première étape est locale, et donne en chaque pixel une mesure d'appartenance à une structure linéaire ; elle utilise les outils développés au chapitre 2. La seconde étape est globale, et travaille sur des segments. Elle réalise l'opération de suivi et donne une interprétation symbolique des routes en s'appuyant sur des connaissances à priori ; elle utilise la méthode markovienne proposée au chapitre 3.

Nous présentons et comparons les résultats sur plusieurs zones d'études choisies pour couvrir les paysages très variés qu'on peut rencontrer en imagerie radar (images de zones plates et structurées des Pays-Bas, relief plus marqué dans les zones de Lorient et d'Aix en Provence, forte présence urbaine dans la région parisienne).

### 4.1.2 Aspect des routes sur des images ROS

Compte tenu de la longueur d'onde en bandes C ou L (5,6 et 23,5cm), le revêtement des routes peut être considéré comme lisse. En effet, si nous adoptons le critère de Rayleigh [Ulab-82], une surface est lisse si  $\Delta h \ll \frac{\lambda}{8 \cos(\theta)}$ , où  $\Delta h$  est l'écart quadratique moyen en hauteur,  $\lambda$  la longueur d'onde et  $\theta$  l'angle d'incidence du satellite. Ici, pour ERS-1,  $\theta = 23^\circ$ , ce qui implique  $\Delta h \ll 0,76$  cm. Cette condition est généralement vérifiée à la surface d'une route avec revêtement.

Dès lors, deux cas de figures sont possibles. Le plus souvent le signal est totalement réfléchi suivant la composante spéculaire ; aucun signal n'est donc rétro-diffusé vers le capteur<sup>1</sup>, et les routes apparaissent alors comme des minima radiométriques. Dans certains cas d'orientations spécifiques, l'onde est réfléchi par des éléments de l'environnement immédiat de la route : talus, glissières, haies, et les routes peuvent apparaître très brillantes sur

---

1. la normale à une route est rarement confondue avec la direction incidente !

l'image (fig.4.1). Ces deux cas sont illustrés sur la figure 4.2. Les routes sont donc des lignes majoritairement sombres, parfois très brillantes, qu'il nous faut détecter dans l'image.

Remarquons également que la visibilité des routes est très dépendante de l'angle d'incidence et des objets qui l'entourent [Hend-88]. Ainsi, de grands axes routiers avec une orientation défavorable, i.e parallèle à la direction incidente, seront très peu marqués sur l'image.

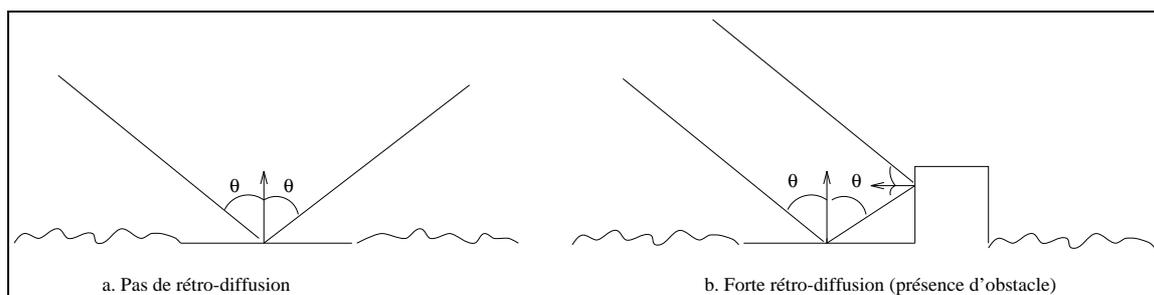


FIG. 4.1 – Exemples de réflexion sur une route

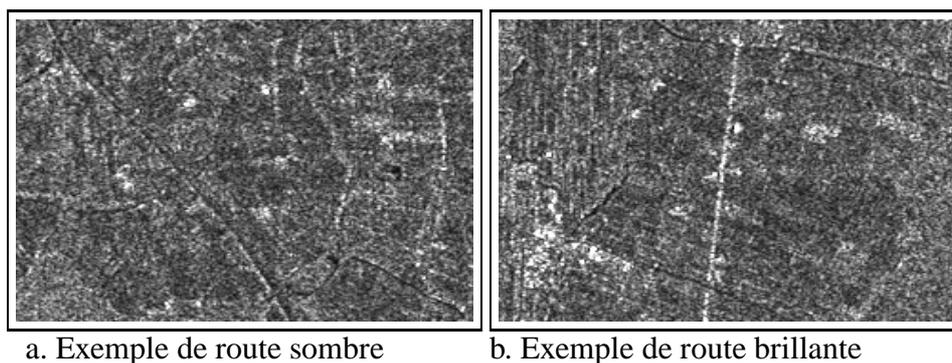


FIG. 4.2 – Exemples de routes (image des Pays-Bas, aux environs de Sneek)

Il est souvent insuffisant et erroné de limiter la détection du réseau routier à celle des structures linéaires [McKeo-88]. En effet, d'autres informations, telles que la nature du revêtement de la route ou la présence de plusieurs voies doivent être prises en compte [Houz-93]. Néanmoins, il faut pour cela disposer d'une résolution suffisante qui n'est généralement pas atteinte en imagerie satellitale. Les traitements locaux que nous utiliserons ici seront donc principalement des méthodes de détection des structures linéaires de largeur 1 à 5 pixels.

### 4.1.3 Méthode de détection

La méthode de détection s'appuie sur les outils développés précédemment et les étapes s'articulent de la façon suivante :

1. détection des structures linéaires sombres ou brillantes,
2. application des post-traitements permettant le passage des pixels aux segments,

3. application de la méthode de connexion markovienne, en injectant une énergie a priori modélisant un objet "route" idéal.

Nous abordons dans cette partie les problèmes pratiques qui se posent lors de la mise en œuvre, notamment le choix des paramètres. Précisons que tous les résultats qui seront montrés dans la suite ont été obtenus avec une même jeu de paramètres fixé une fois pour toutes. Les notations sont celles des chapitres 2 et 3.

### Paramètres des détecteurs D1 et D2 et des post-traitements

Les deux opérateurs sont modifiés pour ne détecter que des structures sombres ou brillantes. En effet, nous imposons :

$$\overline{A}_1 < \overline{A}_2 \text{ et } \overline{A}_1 < \overline{A}_3 \text{ (structures sombres)}$$

$$\overline{A}_1 > \overline{A}_2 \text{ et } \overline{A}_1 > \overline{A}_3 \text{ (structures brillantes)}$$

Les masques utilisés ont 11 pixels de longueur et 7 ou 9 de largeur suivant l'épaisseur de la structure linéaire. Le tableau Tab.4.1 montre les tailles des différentes régions. Le tableau

TAB. 4.1 – Taille des fenêtres de traitement.

Taille au sol	Largeur de la ligne centrale	Nombre de pixels de la région 1	Nombre de pixels de la région 2	Nombre de pixels de la région 3
12,5m	1	11	33	33
25m	2	22	22	33
37,5m	3	33	22	22
62,5m	5	55	22	22

4.2 résume les paramètres intervenant dans l'étape de bas-niveau, et l'étape permettant de passer des pixels aux segments. La taille du voisinage utilisée et le nombre de directions choisi réalisent un compromis entre le taux de fausse alarme des détecteurs et le temps de calcul (cf.§2.3.4). Les seuils utilisés pour D1 et D2 assurent une probabilité de fausse alarme théorique inférieure à 1%. Nous tenons ici à faire trois remarques qui se sont révélées importantes en pratique. Tout d'abord, il est préférable de travailler sur les images 16 bits ayant la dynamique maximale lorsqu'on en dispose. Le passage sur 8 bits se fait au prix ou bien d'une modification des statistiques des images, ou bien d'une très grande perte de dynamique. Ensuite, il est impératif de ne pas travailler sur des images "inversées"<sup>2</sup> pour faire la détection des routes brillantes. Cette opération fausse, bien sûr, totalement les statistiques du chatoiement (les forts écart-types des zones brillantes correspondant alors aux zones sombres). Pour finir, remarquons que le modèle de chatoiement totalement développé qui est utilisé pour l'étude de D1 et D2 n'est pas vérifié en toute rigueur, au moins pour la région centrale dans le cas des routes. En effet, nous avons montré au §4.1.2 que celles-ci étaient lisses (donc le chatoiement n'est pas totalement développé puisqu'il suppose une

2. Nous entendons par là des images de la forme  $A_{max} - A$ , où  $A_{max}$  serait l'amplitude maximale.

TAB. 4.2 – Valeurs des paramètres

Longueur maximale du masque	11 pixels
Largeur maximale du masque	9 pixels
Nombre de directions utilisées	8
Seuil sur le détecteur D1	0,3
Seuil sur le détecteur D2	0,45
Taille des blocs pour la transformée de Hough locale	20 pixels
Angle du faisceau de prospection	45°
Pas de prospection	4 pixels

surface rugueuse par rapport à la longueur d'onde), ou bien vues grâce à des réflexions spéculaires sur leur milieu environnant. En fait, les performances des détecteurs restent bonnes ; d'une part parce qu'une partie du signal est quand même rétro-diffusée<sup>3</sup>, d'autre part parce que l'absence de chatoiement ne peut que rapprocher la valeur de la moyenne empirique de la valeur théorique, et donc faire baisser le taux de fausse alarme.

#### Paramètres de la connexion markovienne

Nous ne redéfinissons pas ici les potentiels des cliques du champ d'étiquettes puisqu'un Obl "route" a été utilisé en exemple lors de la présentation de cette méthode (voir 3.3.2).

Le tableau 4.3 résume les paramètres utilisés. Ils sont déduits des raisonnements faits au §3.5. Les autres paramètres : température initiale,  $\mathcal{D}_{max}$ , etc... ont été fixés empiriquement. La mesure d'un segment est définie comme la mesure moyenne des mesures en chaque pixel (voir §3.3.1).

TAB. 4.3 – Valeurs des paramètres

Température initiale	5
Décroissance géométrique de la température	0,99
Distance maximale pour connecter deux segments $\mathcal{D}_{max}$	100 pixels
Paramètre "extrémité" $K_e$	0,21
Paramètre "longueur" $K_L$	0,12
Paramètre "intersection" $K_i$	0,2
Paramètre "courbure" $K_c$	0,25
Seuil bas pour le potentiel d'attache aux données $t_1$	0,2
Seuil haut pour le potentiel d'attache aux données $t_2$	0,3

Notons que dans le cas de très grands axes routiers, il peut s'avérer intéressant de travailler à une résolution dégradée. Dans ce cas, l'ensemble de la méthode est appliqué sur une

3. Les amplitudes des pixels le long des routes ne sont jamais nulles.

image réduite par moyennage de blocs de pixels. Cette méthode, outre sa rapidité, présente l'avantage de procurer une image dont les statistiques sont les mêmes que celles de l'image initiale à un changement de paramètre près<sup>4</sup>. Les modifications entraînées dans la première étape sont détaillées dans la méthode de détection du réseau hydrographique présentée dans la section suivante (§4.2). En ce qui concerne l'étape de connexion markovienne, les paramètres restent inchangés, sauf la distance maximale pour connecter deux segments qui est ramenée à 60 pixels.

#### 4.1.4 Résultats

La méthode complète a été testée sur un jeu de plusieurs images, avec le même ensemble de paramètres cités précédemment. Comme la majeure partie des routes sont sombres sur ces images, seule cette détection a été effectuée.

Les images sur lesquelles la méthode a été testée se partagent en trois grands groupes :

1. les paysages plats et relativement structurés : images de Flevoland, du Wieringermeer, et des environs de Paris (Roissy) ;
2. les paysages où la présence de relief est relativement importante : images d'Aix en Provence et de Lorient ;
3. le milieu urbain : images de Paris et de son agglomération ;

Une présentation visuelle et une analyse des résultats sont effectuées pour chacun des types d'images testées.

##### Paysages plats et structurés

Ces images sont relativement faciles d'interprétation en raison de l'absence de relief. Les images du Flevoland et du Wieringermeer aux Pays-Bas sont par ailleurs des images de polder, et la présence fréquente de canaux le long des routes facilite leur détection (même si leur différenciation prête à confusion). La comparaison des résultats de la détection et des cartes 4.3 et 4.4<sup>5</sup> montre des taux de détection élevés sur ces zones (voir Tab.4.4).

Comme nous disposions d'une scène RADARSAT de cette même région -CDRom Samples Images-, nous avons testé la méthode sur deux images, l'une du Flevoland fig.4.5a, et l'autre centrée sur Amsterdam fig.4.6a. Là encore, on constate une détection satisfaisante des routes et des canaux (fig.4.5b, fig.4.6b), avec cependant plusieurs fausses détections dans la mer près du port sur l'image des Flevoland. L'image originale montre en effet des sortes de structures linéaires sombres, dues peut-être à des courants marins (fig.4.5a). Le même jeu de paramètres a été utilisé.

---

4. Notons qu'il ne s'agit pas ici de faire de la multirésolution sur le graphe des segments en le décimant (contrairement à un contexte multi-grilles) mais de faire une détection des gros axes routiers à une résolution dégradée.

5. Les résultats seront parfois présentés avec une carte (voir également l'annexe A), mais celle-ci n'est pas toujours recalée par rapport à l'image.

TAB. 4.4 – *Quantification des détections sur les Pays-Bas*

Types de routes (carte)	Nombre total de routes	Routes complètement détectées	Routes partiellement détectées	Non détectées
Autoroutes	4	2	2	0
Routes principales	8	5	2	1
Routes secondaires	6	4	1	1
Autres routes	27	15	6	6
Canaux	18	16	2	0

Les résultats de la détection pour la zone centrée sur l'aéroport de Roissy sont également satisfaisants (figure 4.7).

La figure 4.8 montre aussi un exemple de détection sur une image SIR-X/X-SAR, couvrant une région entre Savergne et Strasbourg (l'autoroute, la route principale et le canal sont bien détectés). Il s'agit d'une image de résolution 10m et d'espacement inter-pixels 6,25m en une vue. Aussi, des seuils plus sévères ont été utilisés pour cette image dans l'étape de détection bas-niveau.

### **Paysages de petites montagnes ou de collines**

Sur des paysages plus difficiles où la présence de relief est plus importante, les routes deviennent de moins en moins visibles. De grands axes routiers, de largeurs comparables, vont être plus ou moins reconnaissables selon leur orientation par rapport à l'angle de visée du radar et selon leur milieu environnant<sup>6</sup>. L'œil, avec un peu d'habitude, est cependant capable de reconnaître une grande partie des axes, même difficilement visibles. Les performances de la méthode automatique sur la seule image ERS1 sont sur ces images bien en dessous des performances de l'œil. Elle fournit cependant un premier résultat avec la détection des grands axes (autoroutes, routes à plusieurs voies), ou des axes particulièrement visibles. Les résultats présentés (région d'Aix en Provence figure 4.9, de Lorient 4.10) illustrent ces difficultés. Les taux de détection diminuent et ceux de fausse alarme augmentent.

### **Milieu urbain**

Pour étudier le comportement de la méthode, nous avons réalisé une expérience en milieu très urbain. Nous donnons ces résultats à titre indicatif, la méthode n'étant pas particulièrement adaptée à ce type d'images. En effet, la présence de nombreux bâtiments met en défaut les hypothèses sur lesquelles se fondent nos détecteurs : les zones de part et d'autre des routes ne peuvent souvent pas être considérées comme homogènes. Pour faciliter la comparaison entre l'image originale et le résultat, seules des petites zones sont présentées.

6. Les axes routiers dont la direction est perpendiculaire à l'axe de visée du radar sont généralement plus visibles que les autres [Hend-88].

La première zone (figure 4.11a et b) se situe entre Clichy et Paris, la seconde (figure 4.11c et d) dans la proche agglomération, aux environs de Taverny.

Nous avons également testé cette méthode sur des images du satellite russe Almaz. D'un angle d'incidence très différent de celui d'ERS-1 ( $50^\circ$ ) et d'une bien meilleure résolution (7,5m ?), les images ont une lisibilité accrue. Un exemple de détection sur une partie de Paris est montré sur la figure 4.12. Les paramètres intervenant dans les deux phases ont été modifiés sur ces images.

#### 4.1.5 Les limites de la méthode

Indépendamment des résultats présentés ci-dessus, nous détaillons dans cette section les hypothèses qui ont été utilisées et évaluons leurs limites. Nous analysons aussi les différents seuils et paramètres qui ont été introduits et étudions leur robustesse.

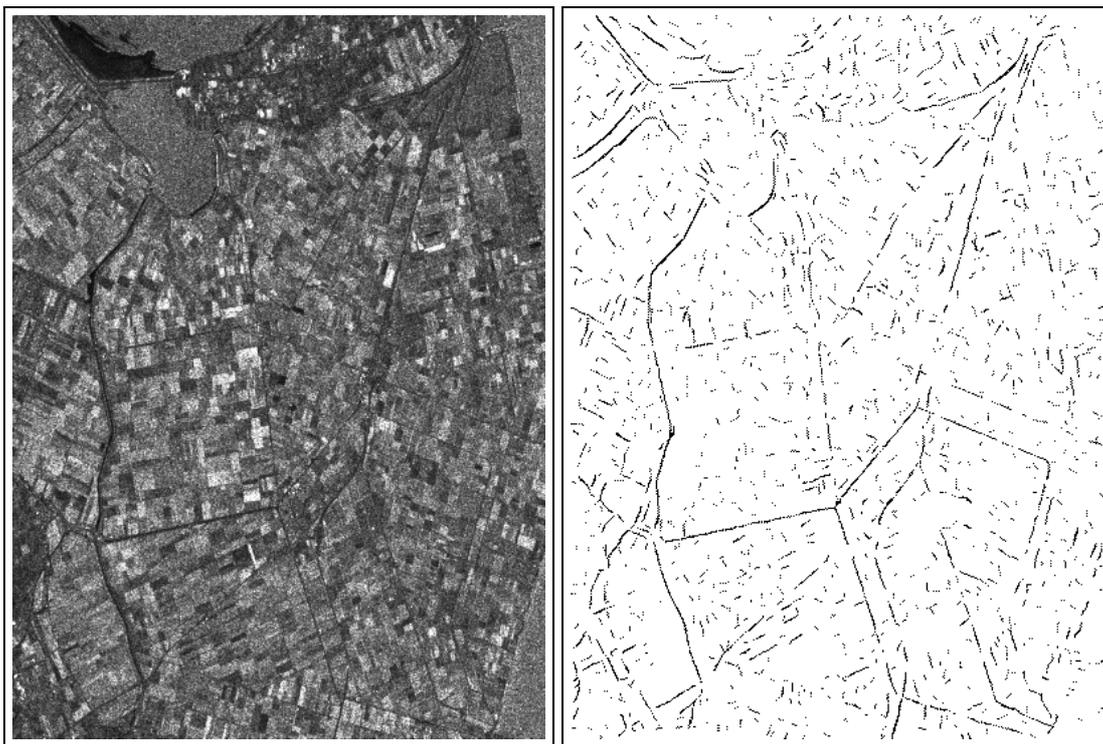
##### Limites et paramètres de la phase locale

Analysons tout d'abord les limites intrinsèques des détecteurs locaux. Nous avons déjà rappelé dans l'introduction que la plupart des caractéristiques qui distinguent les routes des autres objets linéaires ne sont pas visibles (bandes blanches centrales, glissières). Les techniques développées se limitent donc à la détection des structures linéaires possédant une faible (ou forte) radiométrie et des propriétés de continuité suffisantes. Une des hypothèses introduites est que la route doit être d'intensité constante, au moins localement sur la longueur de la zone choisie (ici 11 pixels). On suppose donc qu'il n'y a pas de changements brutaux au niveau du signal réfléchi. Cette contrainte semble raisonnable car le nombre de pixels de routes, variant de 11 à 55 suivant l'épaisseur du modèle, est relativement faible et implique une petite zone de l'image.

Le calcul de la réponse du détecteur D2 implique par ailleurs une radiométrie faiblement variable dans les zones de part et d'autre. Le modèle idéal est en effet défini comme une structure linéaire homogène, encadrée par deux zones également homogènes. Ce modèle est bien sûr loin de la réalité. Les zones peuvent être texturées, ou contenir plusieurs zones homogènes. Il n'est néanmoins pas réaliste d'essayer de limiter le nombre de pixels mis en jeu pour chaque détecteur, car alors les estimations empiriques qui interviennent sont moins fiables, et les probabilités de fausse alarme augmentent.

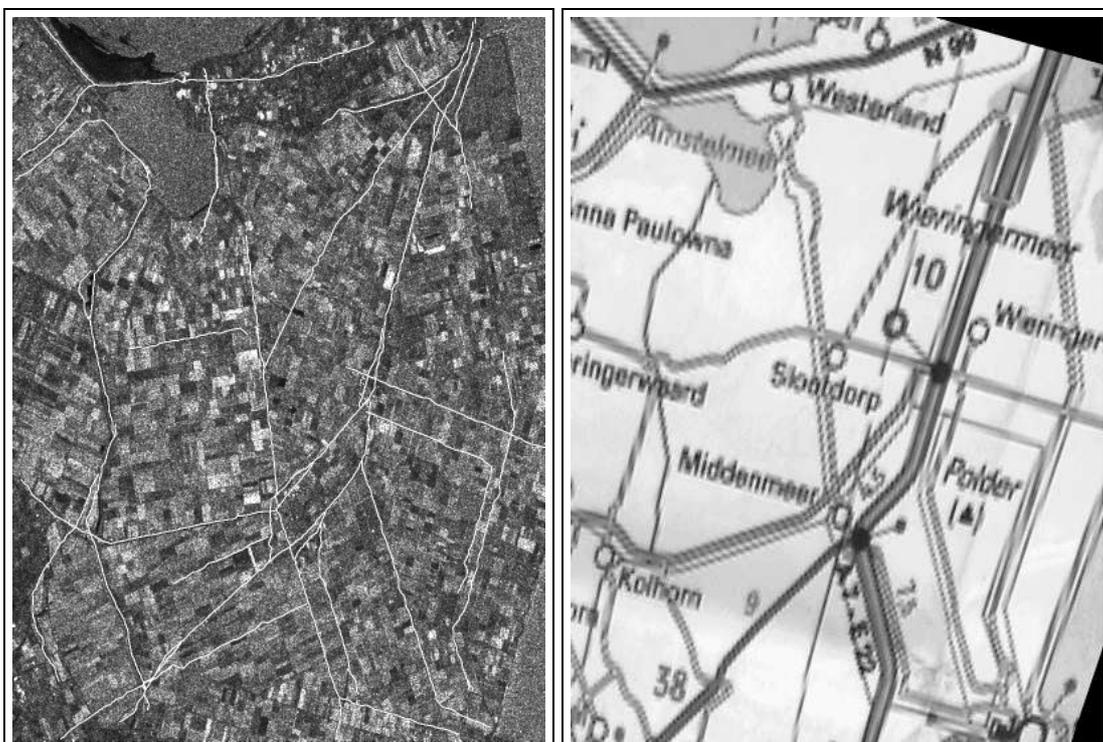
Les seuils intervenant dans cette phase locale sont les seuils de décision sur D1 et D2 (le seuil sur la mesure de fusion est de 0,5), lorsque nous passons à la notion de segments. Il est probable que des seuils adaptatifs permettant de tenir compte de la qualité des images (ou au moins de la visibilité des structures) amélioreraient les résultats. Cependant, la valeur moyenne et l'écart-type de la mesure de fusion se sont révélés très stables (autour de 0,3 pour la moyenne et 0,12 pour l'écart-type sur toutes les images ERS-1). Les valeurs utilisées qui correspondent à l'étude statistique des détecteurs se sont révélées bien adaptées à tous les types d'images (à condition de travailler en 16 bits).

Les temps de calculs de cette première étape bas-niveau (application de D1 et D2, fusion dans les 8 directions et post-traitements) sont de 8 minutes sur une image de taille  $1024 \times 1024$  sur une SPARC Center 2000 (processeur SPARC 10).



a. Image originale (Wieringermeer)  
©ESA (cf. annexe A.2).

b. Résultat final de la phase locale,  
image des segments.



c. Résultat de la détection des routes  
superposé à l'image originale.

d. Carte recalée de la zone de l'image.

FIG. 4.3 – Détection des routes sur le Wieringermeer



a. Image originale (Flevoland aux Pays-Bas) ©ESA (cf. annexe A.2).



b. Résultat de la détection des routes superposé à l'image originale.

FIG. 4.4 – *Détection des routes sur le Flevoland*



a. Image originale (Flevoland aux Pays-Bas) ©Agence Canadienne de l'Espace.



b. Résultat de la détection des routes superposé à l'image originale.

FIG. 4.5 – Détection des routes sur le Flevoland, image RADARSAT

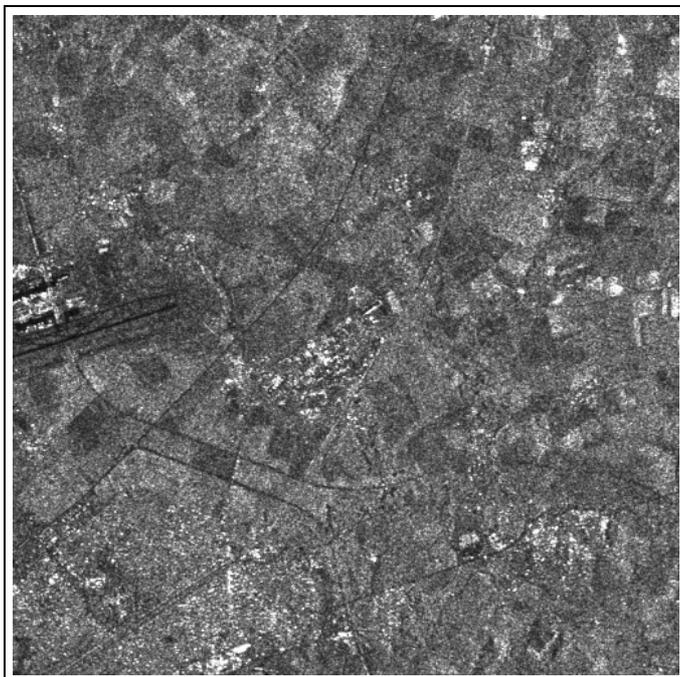


a. Image originale (Amsterdam aux Pays-Bas) ©Agence Canadienne de l'Espace.

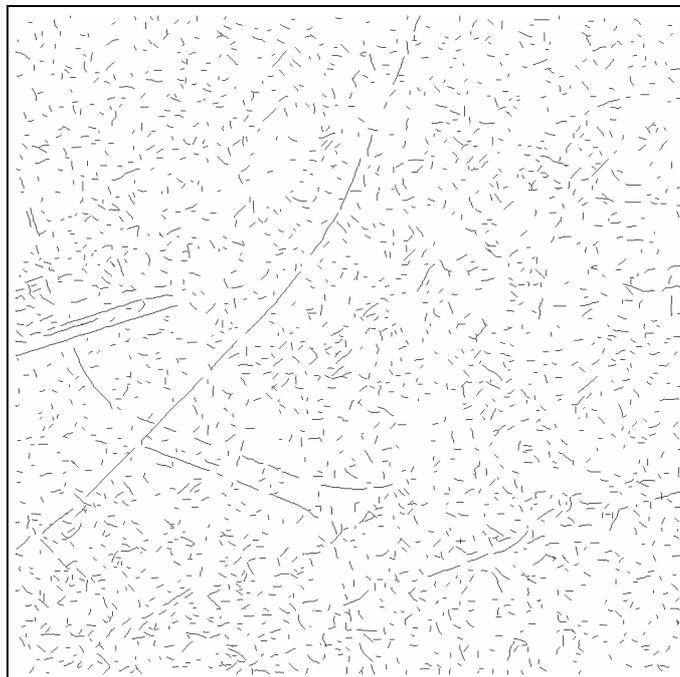


b. Résultat de la détection des routes superposé à l'image originale.

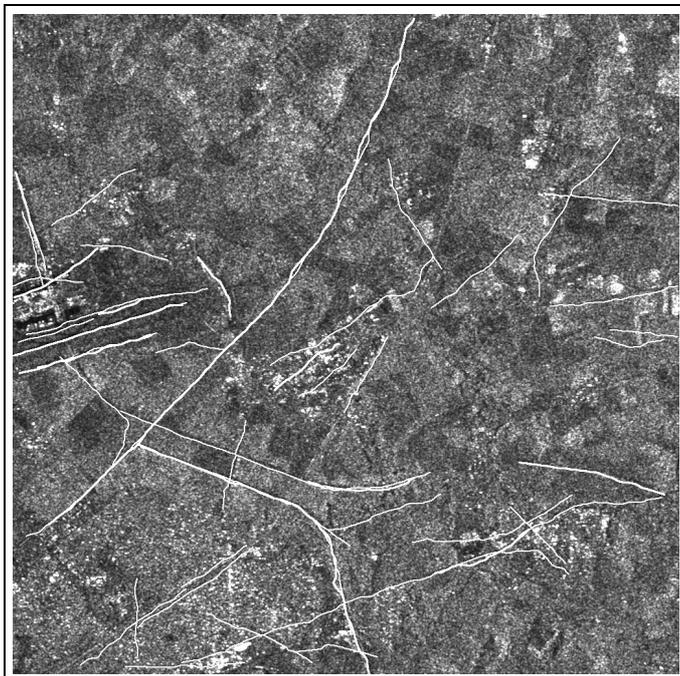
FIG. 4.6 – Détection des routes sur Amsterdam, image RADARSAT



a. Image originale (aéroport de Roissy) ©ESA (cf. annexe A.4).



b. Résultat final de la phase locale, image des segments.

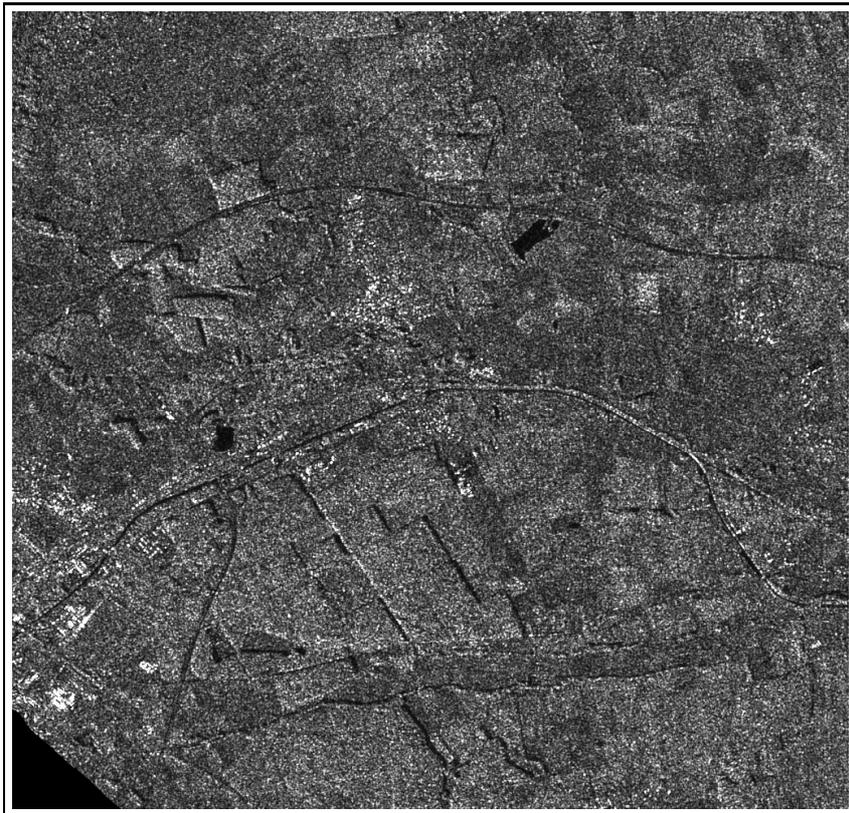


c. Résultat de la détection des routes superposé à l'image originale.

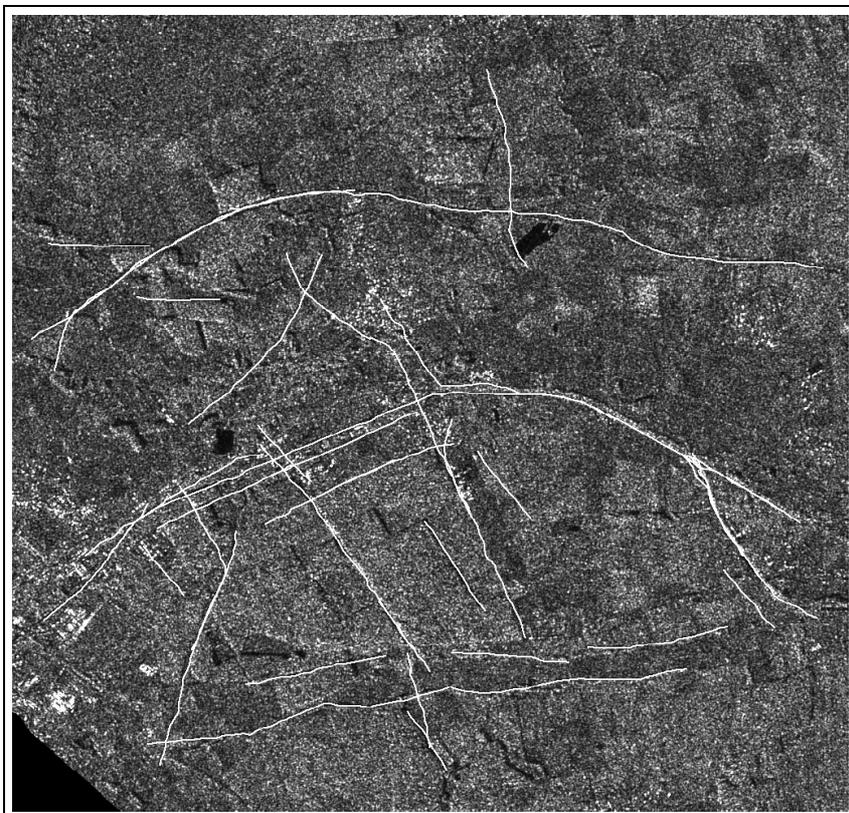


d. Carte recalée de la région.

FIG. 4.7 – Détection des routes sur Roissy

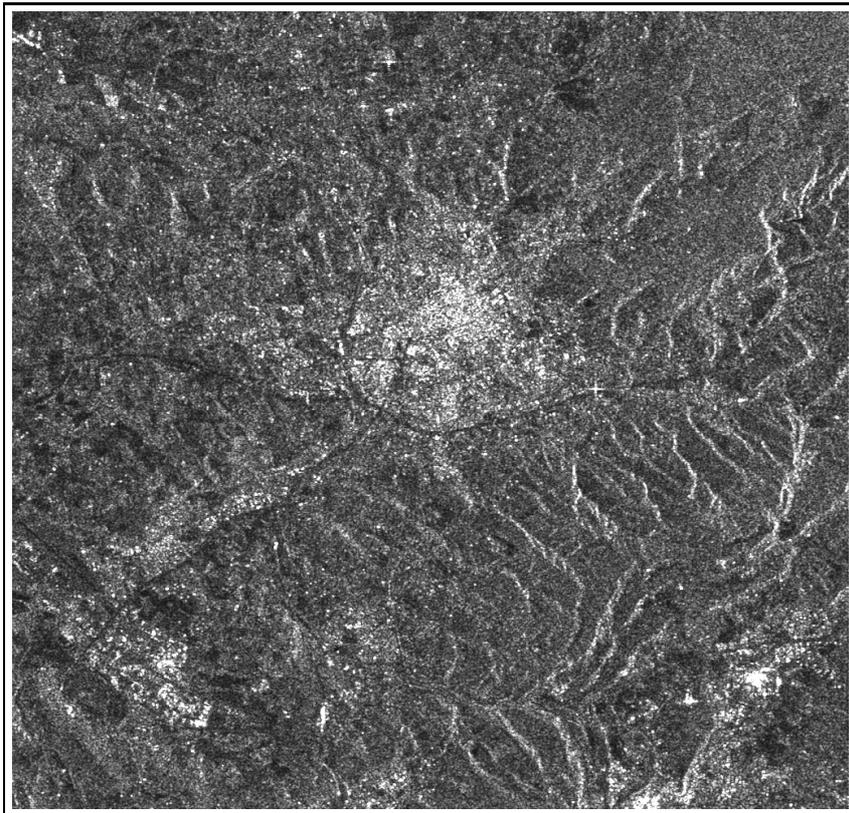


a. Image originale (entre Savergne et Strasbourg) ©DLR/DFD.

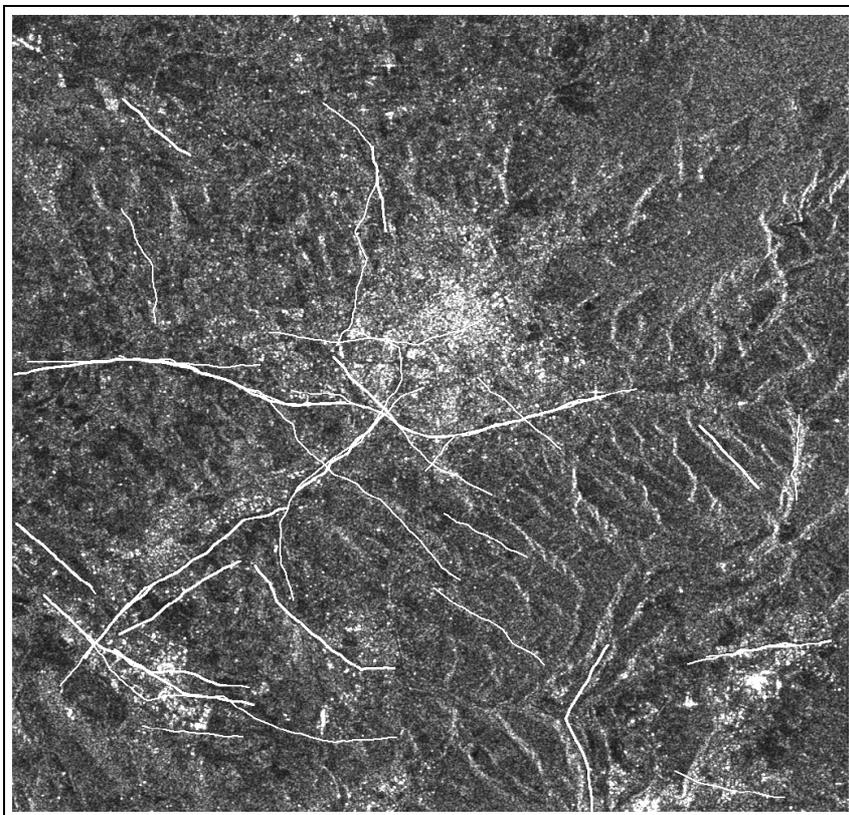


c. Résultat de la détection des routes superposé à l'image originale.

FIG. 4.8 – Détection des routes sur une image SIR-C/X-SAR de la région de Strasbourg

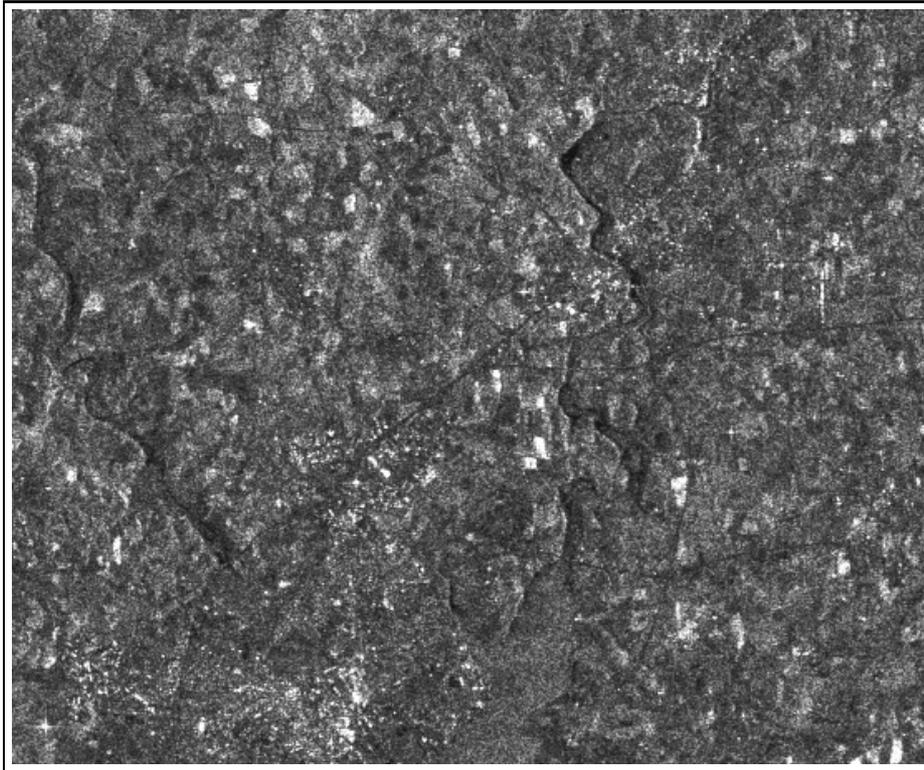


a. Image originale (Aix en Provence) ©ESA (cf. annexe A.5).

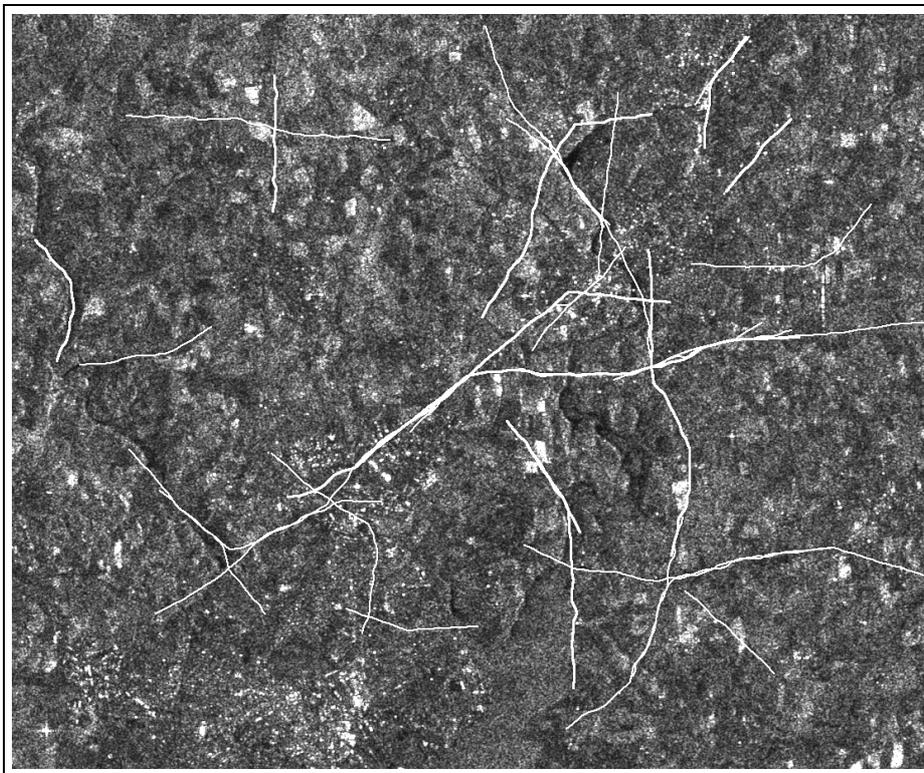


b. Résultat de la détection superposé à l'image originale.

FIG. 4.9 – *Détection des routes sur Aix en Provence*

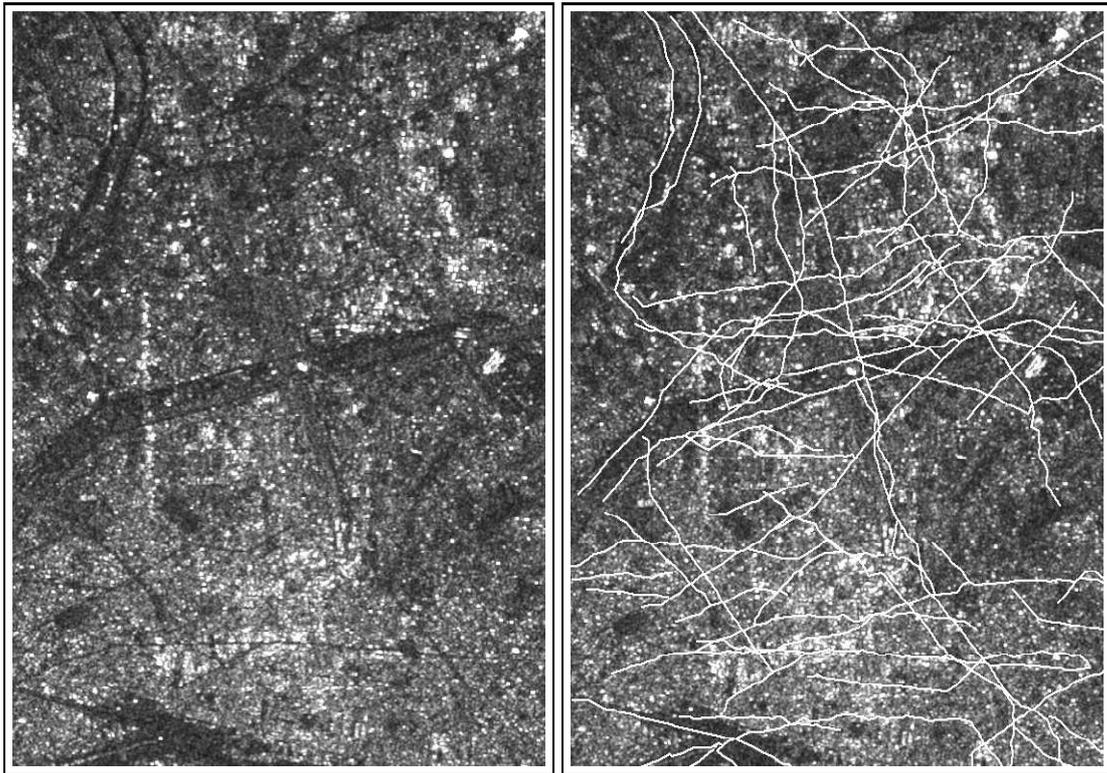


a. Image originale de Lorient ©ESA (cf. annexe A.3).



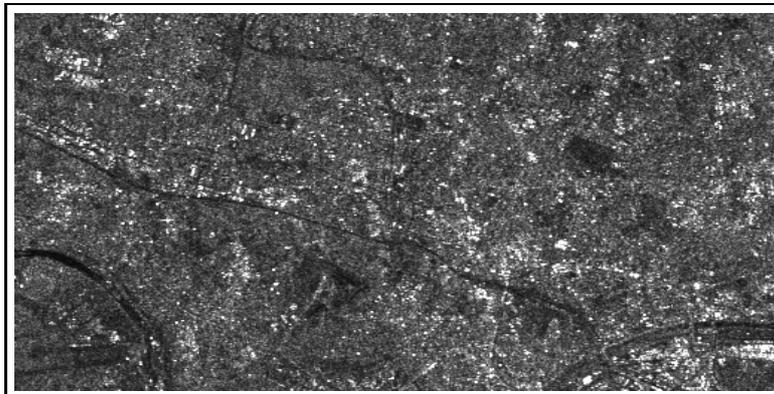
b. Résultat de la détection des routes superposé à l'image originale.

FIG. 4.10 – *Détection des routes sur la région de Lorient*

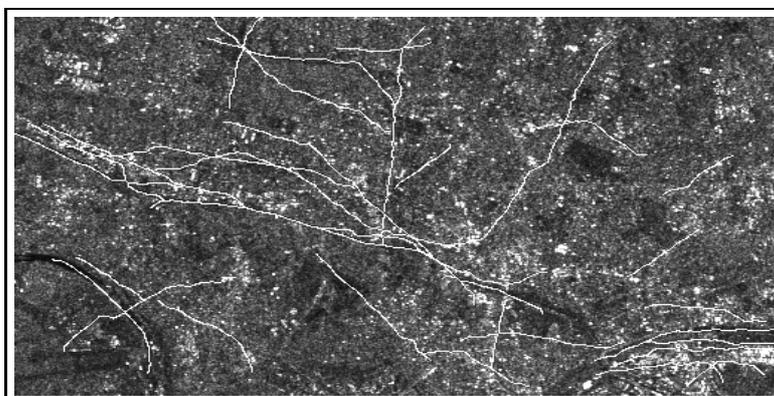


a. Image originale de Paris.

b. Résultat de la détection.

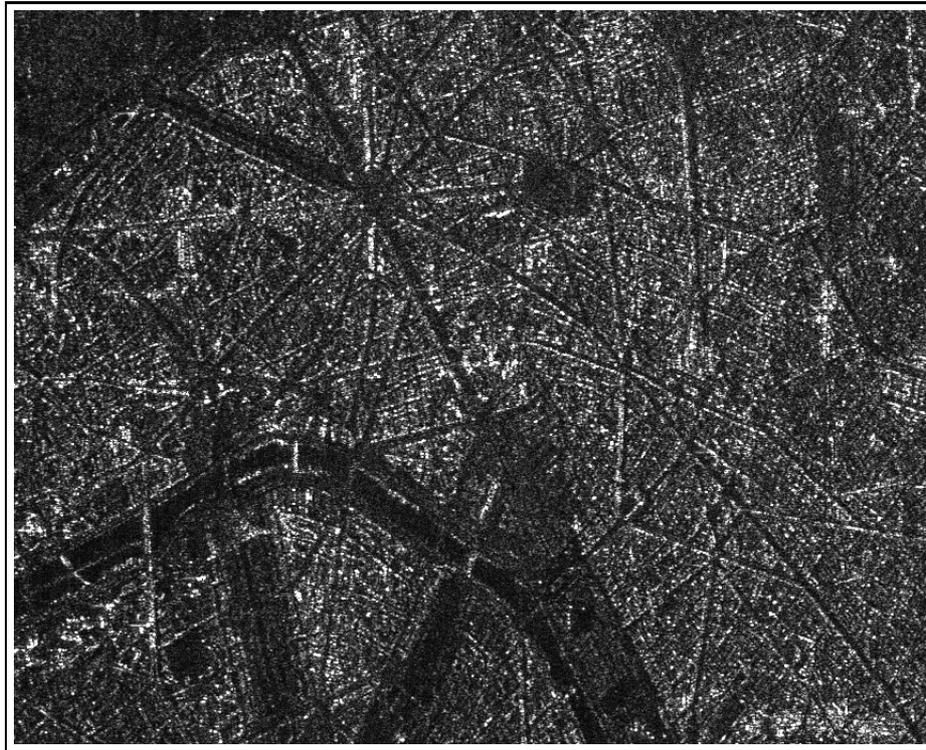


c. Image originale des environs de Taverny.

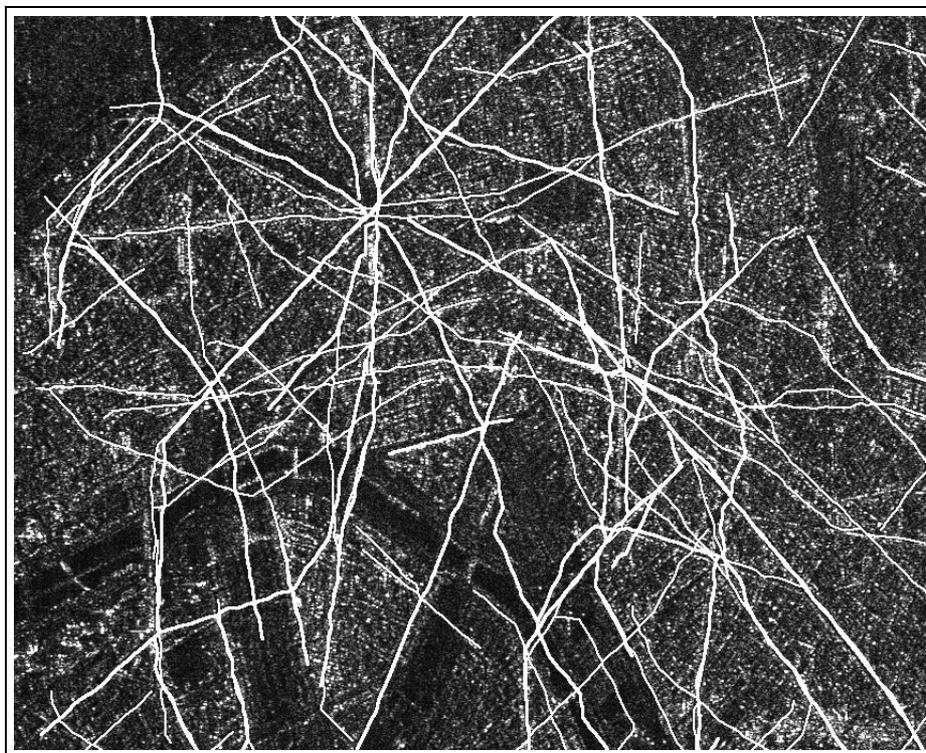


c. Résultat de la détection.

FIG. 4.11 – *Détection des routes en milieu très urbain*



a. Image Almaz originale de Paris.



b. Résultat de la détection des routes.

FIG. 4.12 – *Détection des routes sur une partie de Paris vue par le satellite Almaz.*

## Limites et paramètres de la phase globale

L'un des reproches majeurs adressés aux techniques markoviennes est la multiplicité des paramètres qui interviennent dans les potentiels, et la difficulté d'estimer les valeurs optimales. Nous tenons ici à souligner que même si les résultats pourraient être améliorés en adaptant les paramètres à chaque image, la marge de manœuvre reste relativement réduite. Le paragraphe 3.3.1 montre que les paramètres  $K_e$ ,  $K_L$  et  $K_i$  sont liés directement à la qualité et à la longueur des routes qu'on veut obtenir. De plus, un même ensemble de paramètres permet d'obtenir des résultats satisfaisants -compte tenu de la qualité des images- sur un jeu de données aussi varié que celui présenté plus haut.

Par ailleurs, une des limites intrinsèques de notre méthode est de considérer que les routes à détecter sont constituées par des segments de  $S$ . Nous supposons implicitement que la détection de la phase locale, même si elle est incomplète, nous permet d'obtenir un ensemble de segments sur lequel se trouvent les routes. On pourrait imaginer de "positionner" (avec des snakes par exemple), avant le recuit simulé, le segment reliant deux extrémités détectées plutôt que de joindre leurs extrémités par un segment de droite. Mais il faudrait considérer des snakes bien plus élaborés que ceux de la partie 3.6, et les temps de calculs, déjà longs, augmenteraient assurément.

D'autre part, si la méthode de connexion markovienne a été élaborée pour gérer le cas particulièrement difficile des images radar, elle est néanmoins générique. Aussi, cette technique pourrait être également appliquée à des images optiques, en particulier lorsque des sites contours définis au niveau des pixels ne sont pas suffisants [Urag-96].

Les temps de calculs de cette deuxième étape (création du graphe de segments et recuit simulé sur des triplets) vont de 30 minutes à 2 heures selon la taille du graphe sur une image de taille  $1024 \times 1024$ , avec une température initiale de 5 et une décroissance géométrique de 0,99, pour une SPARC Center 2000 (processeur SPARC 10). Une ICM avec initialisation par l'étape bas-niveau prend environ 5 minutes, mais les résultats sont souvent des minima locaux.

## 4.2 La détection du réseau hydrographique

### 4.2.1 Présentation

Comme la détection du réseau routier, la détection du réseau hydrographique offre de nombreuses applications : surveillance de l'évolution du réseau (crues, assèchements de certains bras...), aide au recalage automatique, aide à la cartographie. Ce réseau apparaît sous forme de structures sombres sur les images radar, très peu de signal étant rétrodiffusé vers le capteur en raison de l'aspect lisse de l'eau et de l'horizontalité de telles surfaces.

La méthode que nous proposons ici est une adaptation de la méthode de détection du réseau routier, faisant également appel aux outils développés dans les chapitres 2 et 3. D'autres méthodes seraient bien sûr envisageables. Sur certaines images où le réseau hydrographique est particulièrement sombre<sup>7</sup>, il est probable qu'un seuillage précisément choisi donnerait

7. cas des images RADARSAT de Guyane, par exemple.

de bons résultats s'il était suivi d'opérations de morphologie mathématique adaptées. La méthode que nous proposons est moins sensible aux conditions radiométriques car elle s'appuie principalement sur la forme linéique du réseau à une échelle donnée et sur la structure a priori d'un fleuve ou d'une rivière.

### 4.2.2 Méthode de détection

#### Organisation générale

Comme pour la détection du réseau routier, la méthode proposée se décompose en deux étapes : une étape locale de détection des structures linéaires, et une étape globale qui connecte les segments obtenus. L'étape locale s'appuie sur le fait que la majorité des fleuves ou rivières apparaissent comme des structures linéaires à une échelle donnée. Ainsi, les détecteurs D1 et D2 sont appliqués à plusieurs résolutions. Ensuite, les différents résultats sont fusionnés et ramenés à l'échelle la plus précise. L'image obtenue est alors seuillée et squelettisée, le problème étant ramené à un problème de connexion comme pour la détection des routes. La méthode markovienne est appliquée en utilisant un Obl "fleuve" et donc des potentiels adaptés, modélisant un fleuve idéal. Finalement, une méthode de repositionnement est appliquée pour retrouver la forme du réseau. L'organigramme de la figure 4.13 résume les opérations effectuées.

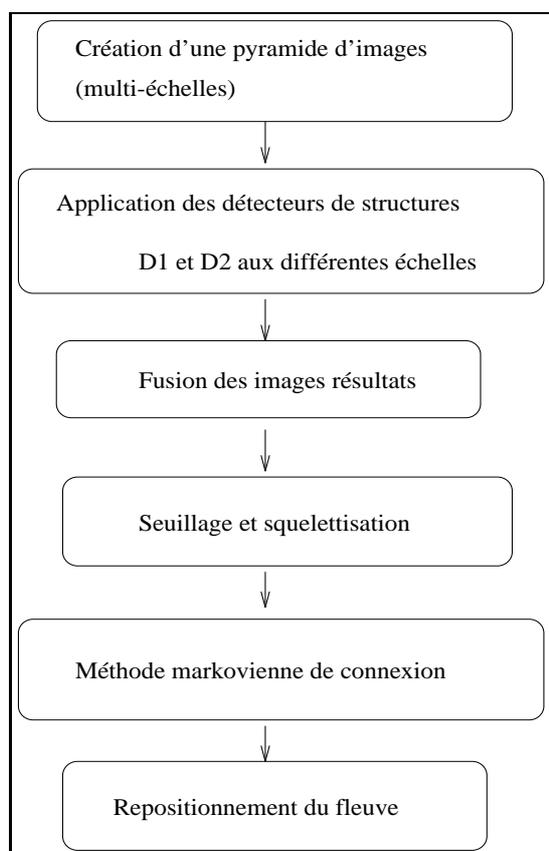


FIG. 4.13 – Méthode de détection du réseau hydrographique

### Création d'une pyramide multi-échelles

Les techniques multi-échelles connaissent actuellement un grand essor, notamment avec les transformées en ondelettes [Meye-92] [Graf-95]. Il ne s'agit pas ici d'exploiter les ressources de telles décompositions, mais de dégrader d'une façon simple la résolution des images. La technique utilisée est un simple moyennage des pixels par blocs de quatre (ou ondelette de Harr) pour passer d'une résolution à une autre. A nos yeux, elle a deux avantages. Tout d'abord, il s'agit d'une opération de multi-vues dans le domaine spatial ; la loi obtenue est donc proche d'une loi gamma généralisée, si l'on tient compte de la corrélation entre les pixels pour obtenir le nombre de vues équivalent. Cela implique que les études statistiques sur les détecteurs de lignes D1 et D2 restent valables. Ce n'est pas le cas pour les autres transformations utilisées. D'autre part, il s'agit d'une technique très rapide et très simple à mettre en œuvre. Notons que pour la préservation des bords des lignes, il aurait mieux valu remplacer la moyenne par un filtre médian ; mais, dans ce cas les statistiques auraient été modifiées.

La pyramide est constituée de quatre images correspondant à des blocs de  $2 \times 2$ ,  $4 \times 4$  et  $8 \times 8$  pixels (nous parlerons dans la suite des échelles ou niveaux 1, 2, 3 et 4, le niveau 1 correspondant à la résolution initiale). Un exemple est montré sur les figures 4.14a, 4.14c et 4.14e.

### Application des détecteurs de structures

Les détecteurs de lignes sont appliqués sur les différentes images moyennées de la pyramide. Les seuils  $r_{min}$  et  $\rho_{min}$  varient bien sûr en fonction de l'échelle. Nous faisons ici une étude succincte des évolutions des détecteurs Dc1 et Dc2 en fonction du nombre de vues.

Les comportements des deux détecteurs évoluent différemment. En effet, la réponse théorique de Dc1 est fondée sur le rapport et elle ne varie donc pas lorsque le nombre de vues augmente. Par contre, comme la valeur de Dc2 entre les régions 1 et 2 est (cf. 2.4.1) :

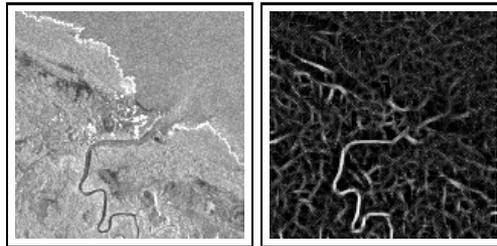
$$\rho_{12}^2 = \frac{1}{1 + (n_1 + n_2) \frac{n_1 \gamma_1^2 c_{12}^2 + n_2 \gamma_2^2}{n_1 n_2 (c_{12} - 1)^2}}$$

elle dépend du coefficient de variation des régions  $\gamma_i = \frac{0.523}{\sqrt{L}}$  et par conséquent varie lorsque le nombre de vues augmente. Ainsi, pour un contraste  $c_{12}$  fixé,  $\rho_{12}$  augmente avec  $L$  (fig.4.15).

En revanche, les densités de probabilité sont, dans les deux cas, de plus en plus reserrées autour de la valeur théorique (fig.4.16). L'évolution des seuils de décision, lorsque le nombre de vues augmente, a donc lieu de la façon suivante :

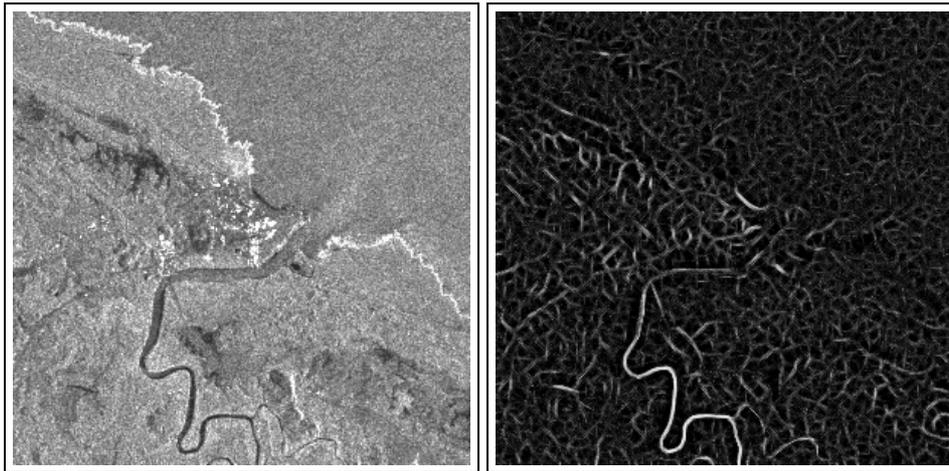
- pour D1 : les distributions sont plus reserrées autour des valeurs théoriques qui ne varient pas ; il faut donc diminuer le seuil de décision pour une même probabilité de fausse alarme ;
- pour D2 : les distributions sont plus reserrées autour des valeurs théoriques qui augmentent ; il faut donc augmenter le seuil de décision pour une même probabilité de fausse alarme.

Le tableau 4.5 illustre ces résultats. Les valeurs  $r_{min}$  et  $\rho_{min}$  choisies sont calculées



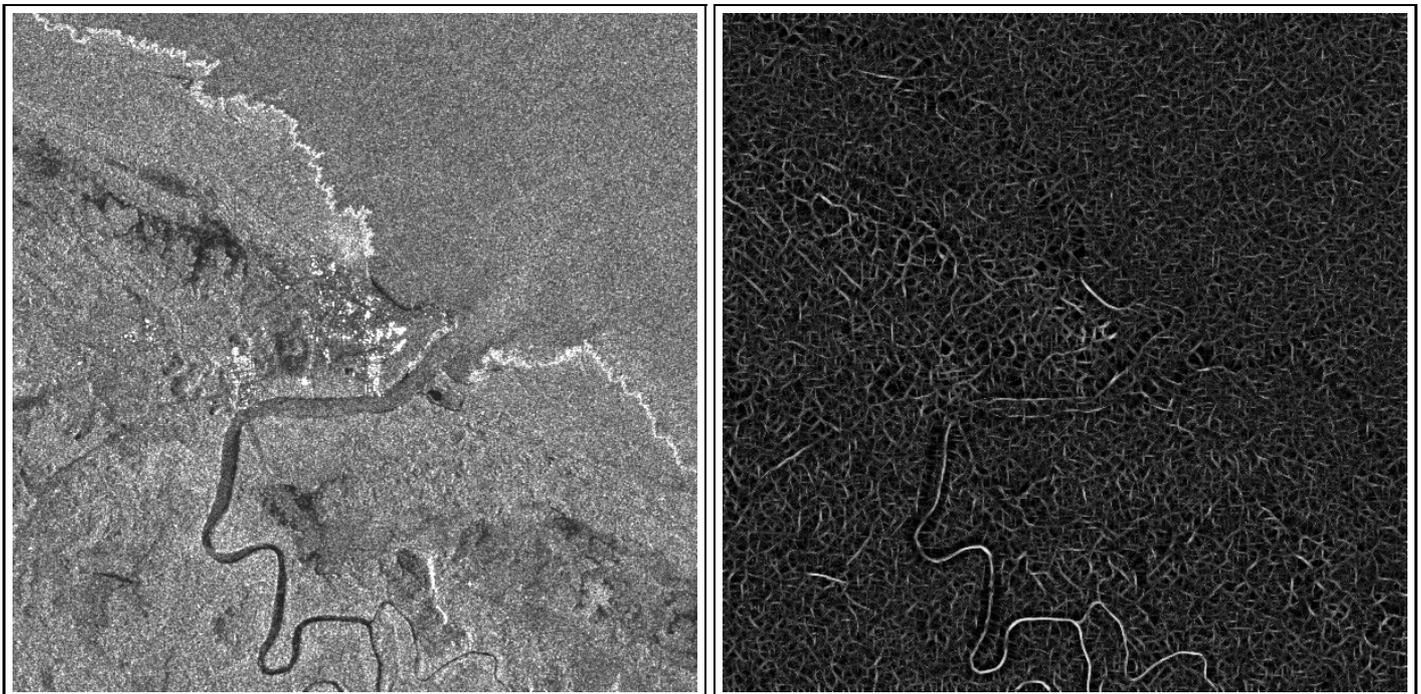
a. Image de Kourou au niveau 4

b. Fusion de D1 et D2 au niveau 4



c. Image de Kourou au niveau 3

d. Fusion de D1 et D2 au niveau 3



e. Image de Kourou au niveau 2

f. Fusion de D1 et D2 au niveau 2

FIG. 4.14 – Pyramide (à gauche les images initiales, à droite le résultat de la fusion de D1 et D2 ; image originale annexe A.6)

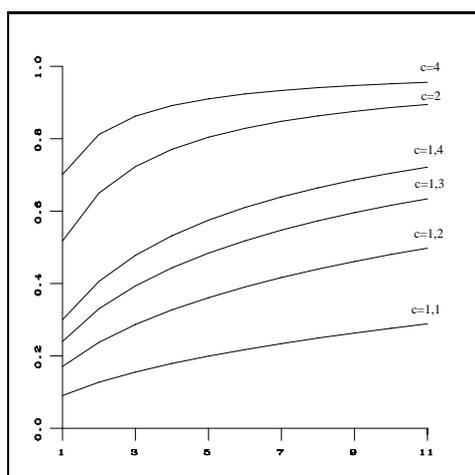
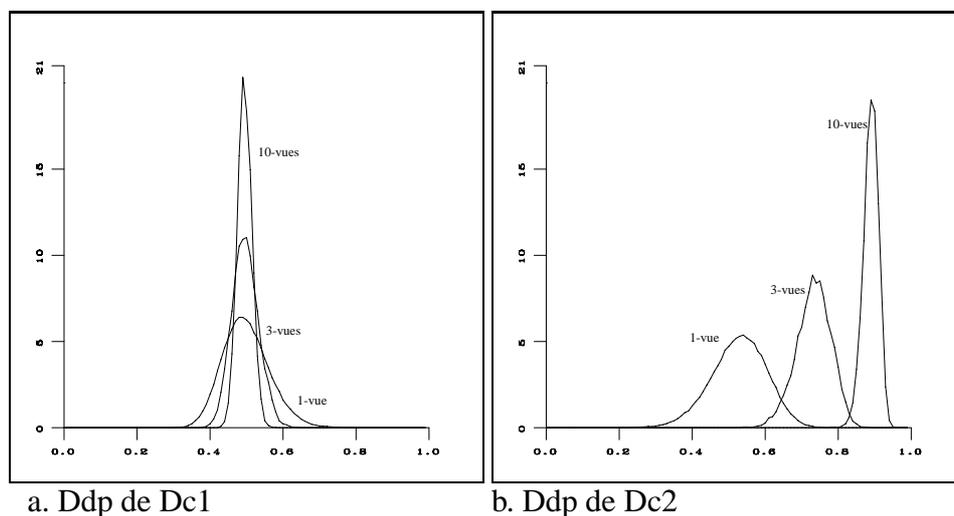


FIG. 4.15 – Valeur théorique de  $\rho_{12}$  pour  $n_1 = n_2 = 33$  en fonction du nombre de vues et pour plusieurs contrastes  $c = c_{12}$ .



a. Ddp de Dc1

b. Ddp de Dc2

FIG. 4.16 – Densités de probabilité de Dc1 et Dc2 pour plusieurs nombres de vues (1, 3, et 10) et un contour de contraste 2.

TAB. 4.5 – Evolution de Dc1 et Dc2 avec le nombre de vues

Détecteur et nombre de vues	Valeur du seuil de décision pour $p_{fa} < 1\%$	Contraste minimum détecté
Dc1 en 3-vues	0,36	1,42
Dc1 en 10-vues	0,43	1,22
Dc2 en 3-vues	0,22	1,48
Dc2 en 10 vues	0,13	1,24

empiriquement sur une zone test et assurent une probabilité de fausse alarme inférieure à 5% ici. Elles sont indiquées dans le tableau 4.6, ainsi que les tailles de masques. A une

TAB. 4.6 – Paramètres de D1 et D2 dans la pyramide

Echelle	$r_{min}$	$\rho_{min}$	longueur du masque	largeur du masque
Niveau 1	0,45	0,3	5	4
Niveau 2	0,45	0,3	4	3
Niveau 3	0,5	0,3	3	3
Niveau 4	0,5	0,2	3	3

échelle donnée, les réponses de D1 et D2 sont ensuite fusionnées comme indiqué dans le §2.7. Des résultats sont montrés sur la figure 4.14b, 4.14d et 4.14f.

### Fusion des différentes échelles

Toutes les images résultats sont ramenées à la résolution initiale. Le passage du niveau  $n$  au niveau  $n - 1$  se fait en remplaçant un pixel par un bloc de quatre pixels. Cette opération est suivie d'une fermeture en niveaux de gris pour limiter les effets de blocs.

Notons  $m_i$  le résultat de la fusion de D1 et D2 pour le niveau  $i$ . Nous cherchons donc à définir un opérateur  $F$  pour fusionner les informations  $m_i$  en une seule. Deux cas sont possibles :

- il n'y a pas de structure, dans ce cas  $\forall i m_i < 0,5$  ;
- il y a une structure dans l'image, dans ce cas elle peut apparaître à une échelle, voire deux.

Soit  $\tilde{F}$  un opérateur de fusion entre deux niveaux. Alors nous pouvons définir  $F$  par :

$$F(m_n, \dots, m_o) = \tilde{F}[\tilde{F}[\dots[\tilde{F}(m_n, m_{n-1}), m_{n-2}], \dots], m_o]$$

Il nous suffit donc de choisir  $\tilde{F}$  en tenant compte de la remarque précédente. Nous avons déjà parlé de l'opérateur de fusion  $\sigma_o$  qui est une somme associative symétrique [Bloc-96] §2.7. Cet opérateur a un comportement indulgent (disjonctif) pour les fortes valeurs des mesures, et sévère (conjonctif) pour les faibles valeurs. Nous proposons de définir  $\tilde{F}(x, y)$  par :

$$\begin{aligned} \min(x, y) > 0,5 &\Rightarrow \tilde{F}(x, y) = \sigma_o(x, y) \\ \max(x, y) < 0,5 &\Rightarrow \tilde{F}(x, y) = \sigma_o(x, y) \\ \max(x, y) > 0,5 \text{ et } \min(x, y) < 0,5 &\Rightarrow \tilde{F}(x, y) = \max(x, y) \end{aligned}$$

Cet opérateur a bien le comportement souhaité ; en l'absence de structure ( $\max(x, y) < 0,5$ ) une faible mesure est obtenue par le comportement conjonctif ; en présence de structure ( $\max(x, y) > 0,5$ ), une mesure supérieure à 0,5 est obtenue, que la structure apparaisse à une ou deux échelles.

Et finalement, les comportements de l'opérateur  $F$  sont résumés ainsi :

- il n'y a pas de structure : dans ce cas  $\forall i m_i < 0,5$  et donc :

$$F(m_n, \dots, m_o) = \sigma_o[\sigma_o[\dots[\sigma_o(m_n, m_{n-1}), m_{n-2}], \dots], m_o]$$

- il y a une structure dans l'image :
  - ◊ si elle apparait à une seule échelle  $j$  :

$$F(m_n, \dots, m_o) = m_j \text{ puisque } \forall i \neq j m_i < 0,5$$

- ◊ si elle apparait à deux échelles  $j$  et  $j - 1$  :

$$F(m_n, \dots, m_o) = \sigma_o(m_j, m_{j-1})$$

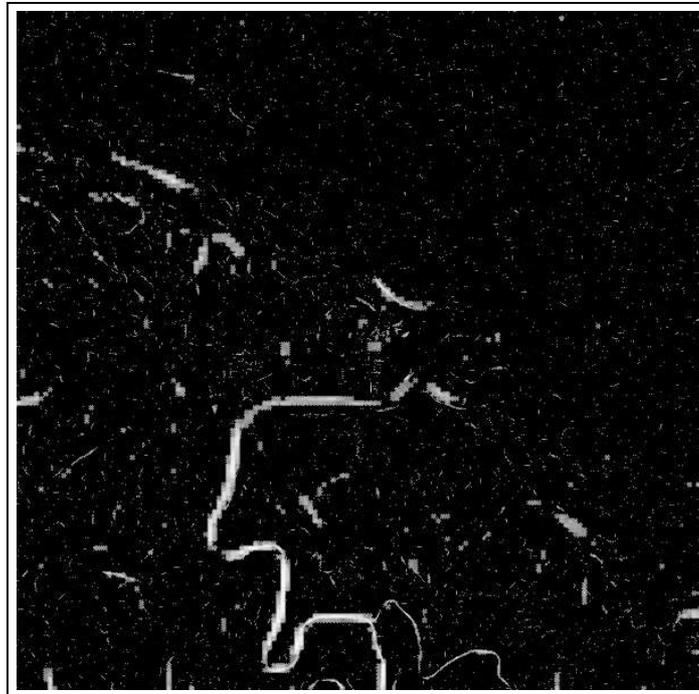


FIG. 4.17 – Résultat de la fusion des niveaux 2, 3 et 4.

La figure 4.17 montre le résultat de la fusion sur le même exemple. Elle a pour effet de réduire les fausses alarmes tout en rehaussant les valeurs des structures.

### Application de la méthode de connexion

Le résultat précédent est ensuite seuillé (à une mesure de 0,5) et squelettisé, puis transformé en segments (voir le §2.8).

La méthode de connexion markovienne reste pratiquement la même que celle utilisée pour les routes, mais l'objet est modélisé différemment. Les contraintes que nous imposons sont les suivantes :

- ◊ (i) un fleuve est une longue chaîne de segments qui ne s'arrête jamais

- ◇ (ii) le cours peut être sinueux
- ◇ (iii) il peut y avoir des embranchements

Cette nouvelle modélisation entraîne plusieurs modifications. Tout d'abord, le graphe des segments est construit en relâchant la contrainte d'"alignement" pour les segments qui sont "proches" (§3.2). Ensuite, les paramètres des potentiels des cliques de l'énergie a priori doivent être modifiés. La définition suivante a été utilisée :

$$\begin{aligned} \forall s_i \in c, l_i = 0 &\Rightarrow V_c(l) = 0 \\ \exists! s_i \in c / l_i = 1 &\Rightarrow V_c(l) = K_e - K_{\mathcal{L}} \mathcal{L}_i \\ \exists!(s_i, s_j) \in c^2 / l_i = l_j = 1, &\Rightarrow V_c(l) = -K_{\mathcal{L}}(\mathcal{L}_i + \mathcal{L}_j) + K_c \sin \mathcal{R}_{ij} \end{aligned}$$

dans tous les autres cas  $V_c(l) = K_i \sum_{i/s_i \in c} l_i$

La contrainte (i) entraîne une très forte pénalisation des extrémités, donc  $K_e$  est pris élevé. Ce choix impose également à toute chaîne de segments d'être longue, et  $K_{\mathcal{L}}$  ne joue plus alors un rôle prédominant. La contrainte (ii), outre la modification de la construction du graphe, impose  $K_c$  faible et (iii) impose  $K_i$  faible.

Nous allons distinguer deux cas : les fleuves de type européen (nous entendons par là un cours relativement régulier) où des contraintes d'alignement peuvent être utilisées, et les fleuves tropicaux parfois très sinueux. La différence de traitement résidera dans la construction du graphe : dans le premier cas, on accepte une distance de connexion grande (100 pixels environ), alors que dans le second, où les détections sont souvent de meilleure qualité, une distance beaucoup plus faible sera utilisée. Le tableau 4.7 donne les valeurs des paramètres. La différence de  $K_e$  entre les deux cas s'explique par le fait que la détection est

TAB. 4.7 – Paramètres de D1 et D2 dans la pyramide

Paramètre	Fleuve peu sinueux	Fleuve sinueux
$K_e$ "extrémité"	0,2	0,5
$K_{\mathcal{L}}$ "longueur"	0	0
$K_c$ "courbure"	0,1	0,1
$K_i$ "intersection"	0,2	0,2
$\mathcal{D}_{max}$ "distance maximale"	100	40

plus difficile dans les paysages "européens", où l'environnement peut perturber la détection des structures linéaires et où les fausses alarmes sont plus nombreuses. On accepte alors de détecter séparément plusieurs parties du fleuve, contrairement aux zones tropicales où l'on peut facilement imposer la détection d'une unique branche. Notons aussi que lorsque  $K_e$  est très élevé, de petites structures circulaires peuvent être obtenues.

Par ailleurs, l'énergie d'attache aux données est calculée à l'échelle où la structure a été détectée. Si deux échelles sont possibles, celle donnant la meilleure mesure est sélectionnée. Comme pour les routes, la mesure d'un segment est la moyenne des mesures de chaque pixel du segment.

### 4.2.3 Le repositionnement du fleuve

Un algorithme de croissance du fleuve est utilisé pour le repositionner<sup>8</sup>. La méthode que nous proposons consiste à effectuer des segmentations successives le long du fleuve, les deux classes considérées étant "fleuve" et "non-fleuve".

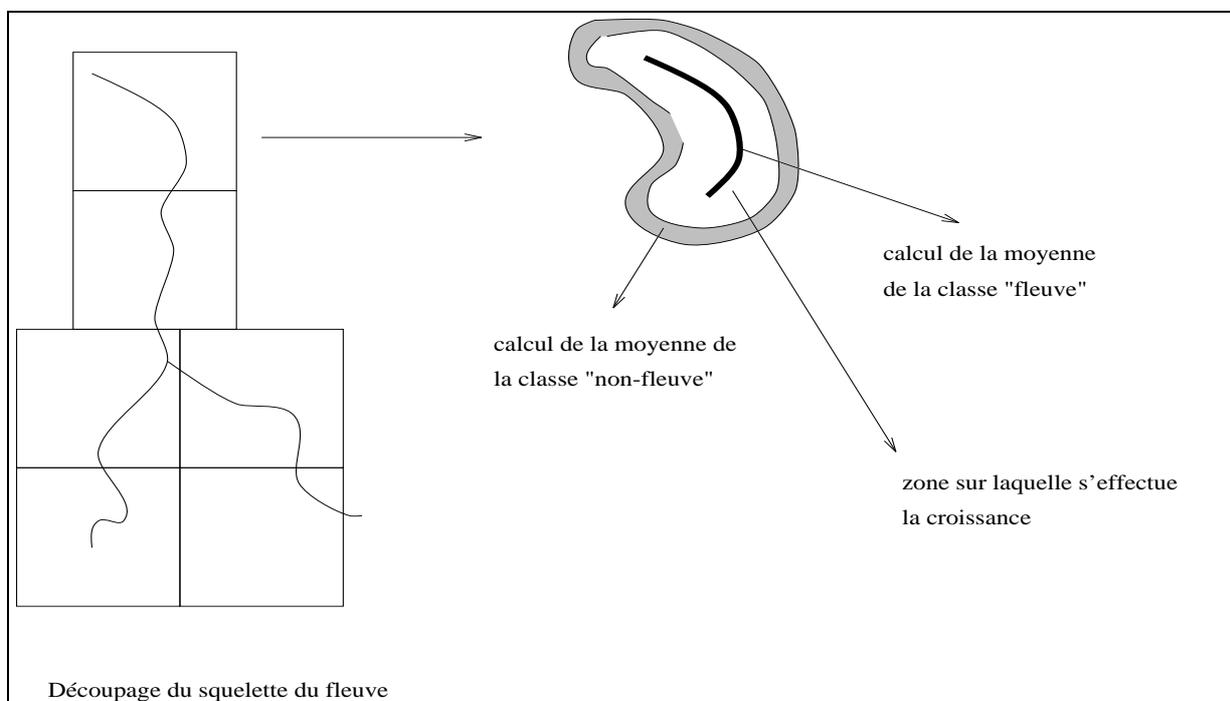


FIG. 4.18 – *Segmentation du fleuve*

Ainsi, le squelette obtenu est découpé en plusieurs parties, notées  $\mathcal{P}_i$ , que l'on suppose localement homogènes. Sur chacune de ces parties, est alors calculée la valeur radiométrique moyenne du fleuve en utilisant les pixels du squelette. La valeur radiométrique moyenne de la région qui le borde (classe "non-fleuve") est calculée dans un ruban suffisamment éloigné du fleuve (4.18).

Pour chaque  $\mathcal{P}_i$  un champ de Markov est alors défini permettant d'étiqueter les pixels compris entre ces deux régions et de les classer "fleuve" ou "non fleuve". La méthode est détaillée dans la technique de segmentation du chapitre 6. Le modèle contextuel utilisé est un modèle de Potts. La minimisation de l'énergie est effectuée par un ICM, et les composantes initiales du fleuve ont une étiquette fixe. Ainsi, il s'agit plutôt d'une croissance de régions gouvernée par deux termes (un terme d'attache aux données radiométrique et un terme contextuel) que d'une segmentation markovienne proprement dite.

Une remarque est à prendre en compte dans la pratique. Le calcul de la moyenne peut être fortement perturbé pour la classe "non fleuve" lorsque le fleuve est bordé par des zones urbaines. En effet, les échos des réflecteurs spéculaires peuvent augmenter anormalement la valeur moyenne [Goui-96]. Une solution consiste à supprimer dans ce calcul toutes les

8. Il ne s'agit pas seulement ici de retrouver une précision au niveau du pixel à partir des segments, mais de reconstruire la forme du fleuve à partir du squelette.

valeurs au-dessus d'un seuil fixe (par exemple  $\mu + 3\sigma$  où  $\mu$  et  $\sigma$  sont la moyenne et l'écart-type calculés sur toute l'image).

#### 4.2.4 Résultats

Nous illustrons les résultats sur deux types de paysages : les paysages tropicaux et les paysages européens.

Sur les paysages tropicaux, la détection est relativement facile car l'environnement souvent très homogène perturbe assez peu la détection locale. Néanmoins, il arrive que les variations radiométriques du fleuve soient importantes, ce qui justifie l'utilisation d'une telle méthode. Les résultats sont illustrés sur les figures 4.19.

Sur les paysages européens, l'environnement notamment urbain et routier peut causer plusieurs fausses alarmes. Cependant, les résultats obtenus sont satisfaisants dans les deux cas (fig.4.20), même si le réseau routier très visible, comme l'autoroute sur l'image de la Seine, est parfois détecté avec le réseau hydrographique.

### 4.3 La détection des zones de relief marqué

#### 4.3.1 Présentation

Cette application, au même titre que les précédentes, s'inscrit dans le cadre de notre travail qui consiste à donner une première interprétation du paysage. Or la présence de relief au sol perturbe fortement la formation de l'image (§1.2.2). Elle se caractérise en particulier par des structures très brillantes, plus ou moins fines, situées à proximité des lignes de crête, comme le montre la figure 4.21. Ces lignes brillantes sont souvent organisées en groupes de directions proches le long du flanc de la montagne.

L'objectif de notre détection est de repérer de telles zones, puis de tenir compte de ce phénomène lors de l'étape d'interprétation. La détection du réseau routier, par exemple, est rendue très peu fiable dans ces régions. Cependant, cette application a un autre intérêt plus général pour l'interférométrie. Sur les versants de trop fortes pentes, les variations de phase dues aux franges topographiques sont en effet supérieures à  $\pi$  entre deux pixels voisins [Trou-96]. L'image est sous-échantillonnée pour ces régions où le développement des franges devient impossible en raison des ruptures de continuités. La détection des lignes brillantes, qui coïncident avec ces ruptures, a donc un intérêt pour le développement automatique de la phase en interférométrie [Trou-96] [Tupi-96c].

#### 4.3.2 Méthode de détection

Comme pour les autres applications, les traitements s'effectuent en deux étapes. Nous appliquons d'abord les détecteurs de structures linéaires brillantes, puis nous regroupons ces structures en éléments de relief à l'aide de critères directionnels et de proximité.

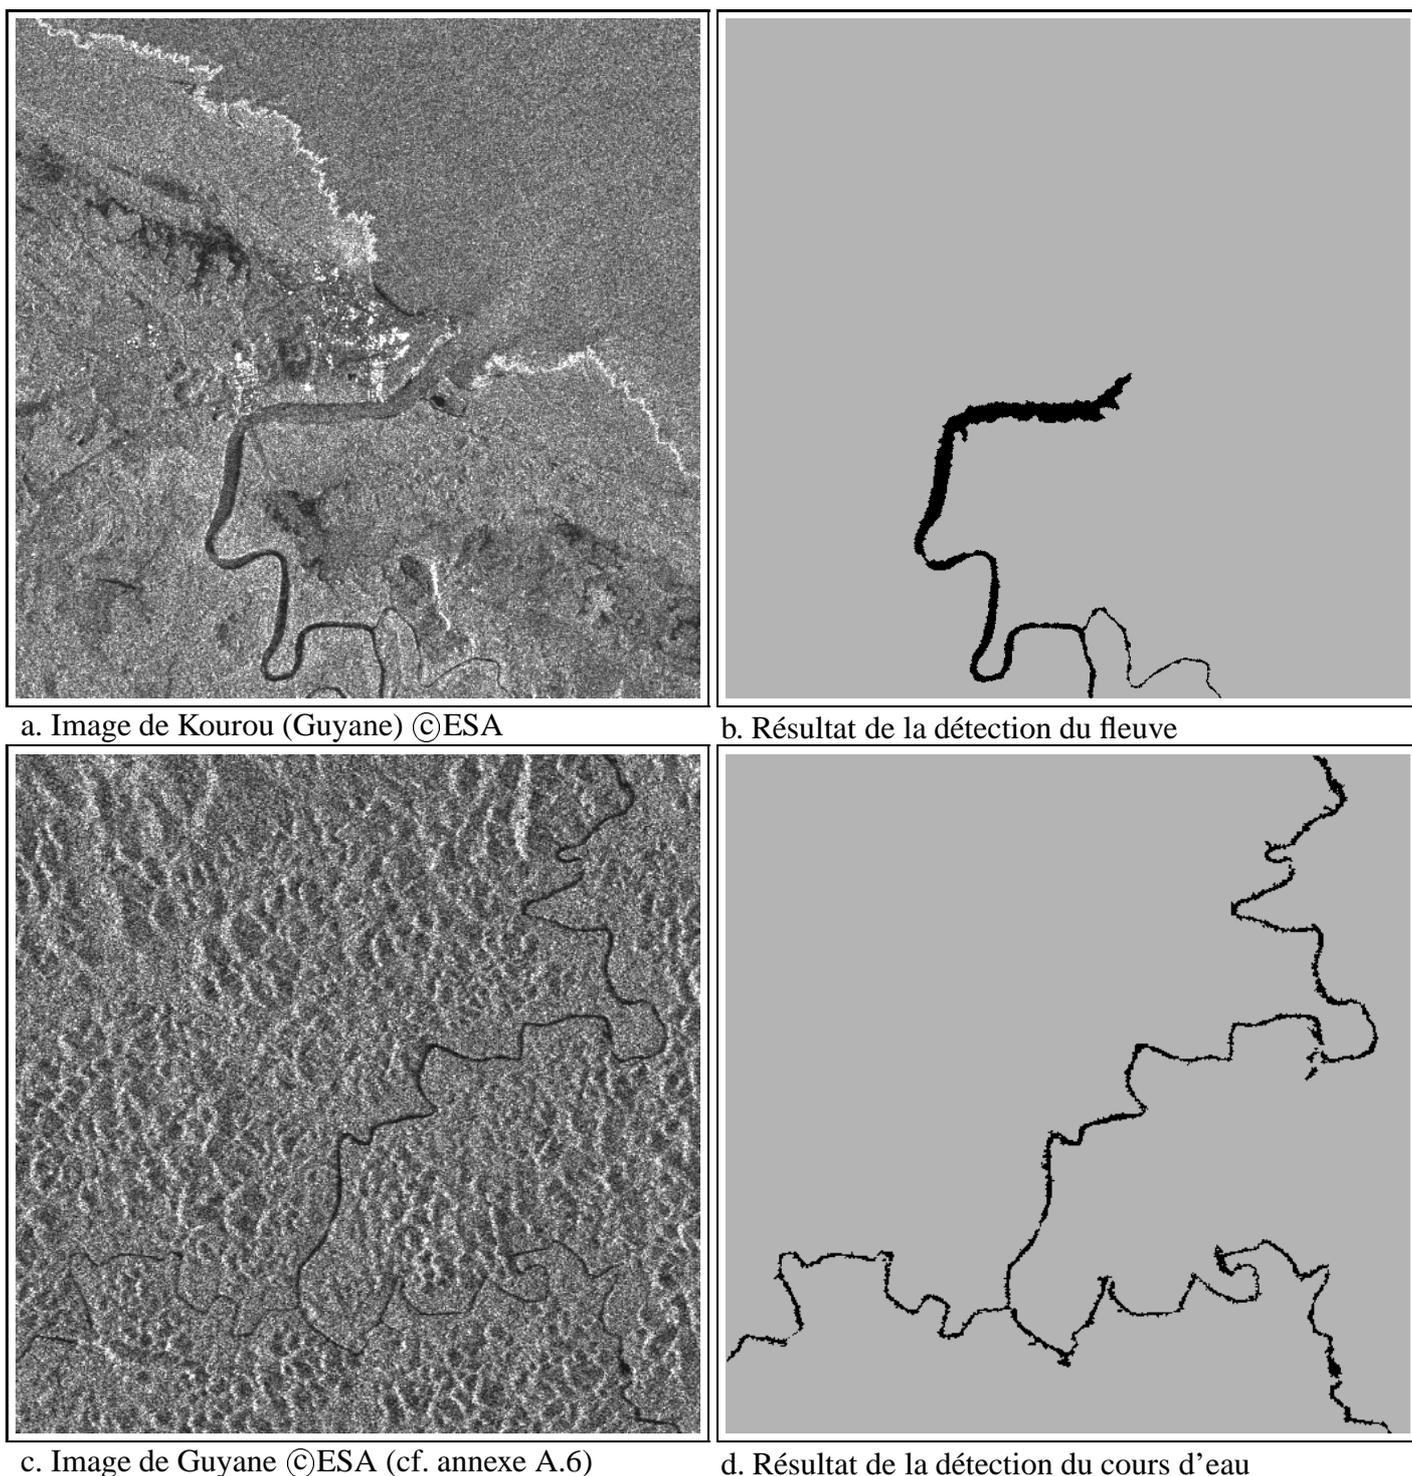


FIG. 4.19 – Détection du fleuve Kourou (en haut) et de ses bras (en bas)

La première étape est facilitée par le très grand contraste des structures du relief. Néanmoins, il faut supprimer les réponses dues à des réflecteurs spéculaires. Ceux-ci entraînent en effet de fortes valeurs de  $D1$  pour plusieurs pixels formant une étoile autour du centre du réflecteur. Ces réflecteurs sont donc préalablement détectés par une méthode proposée

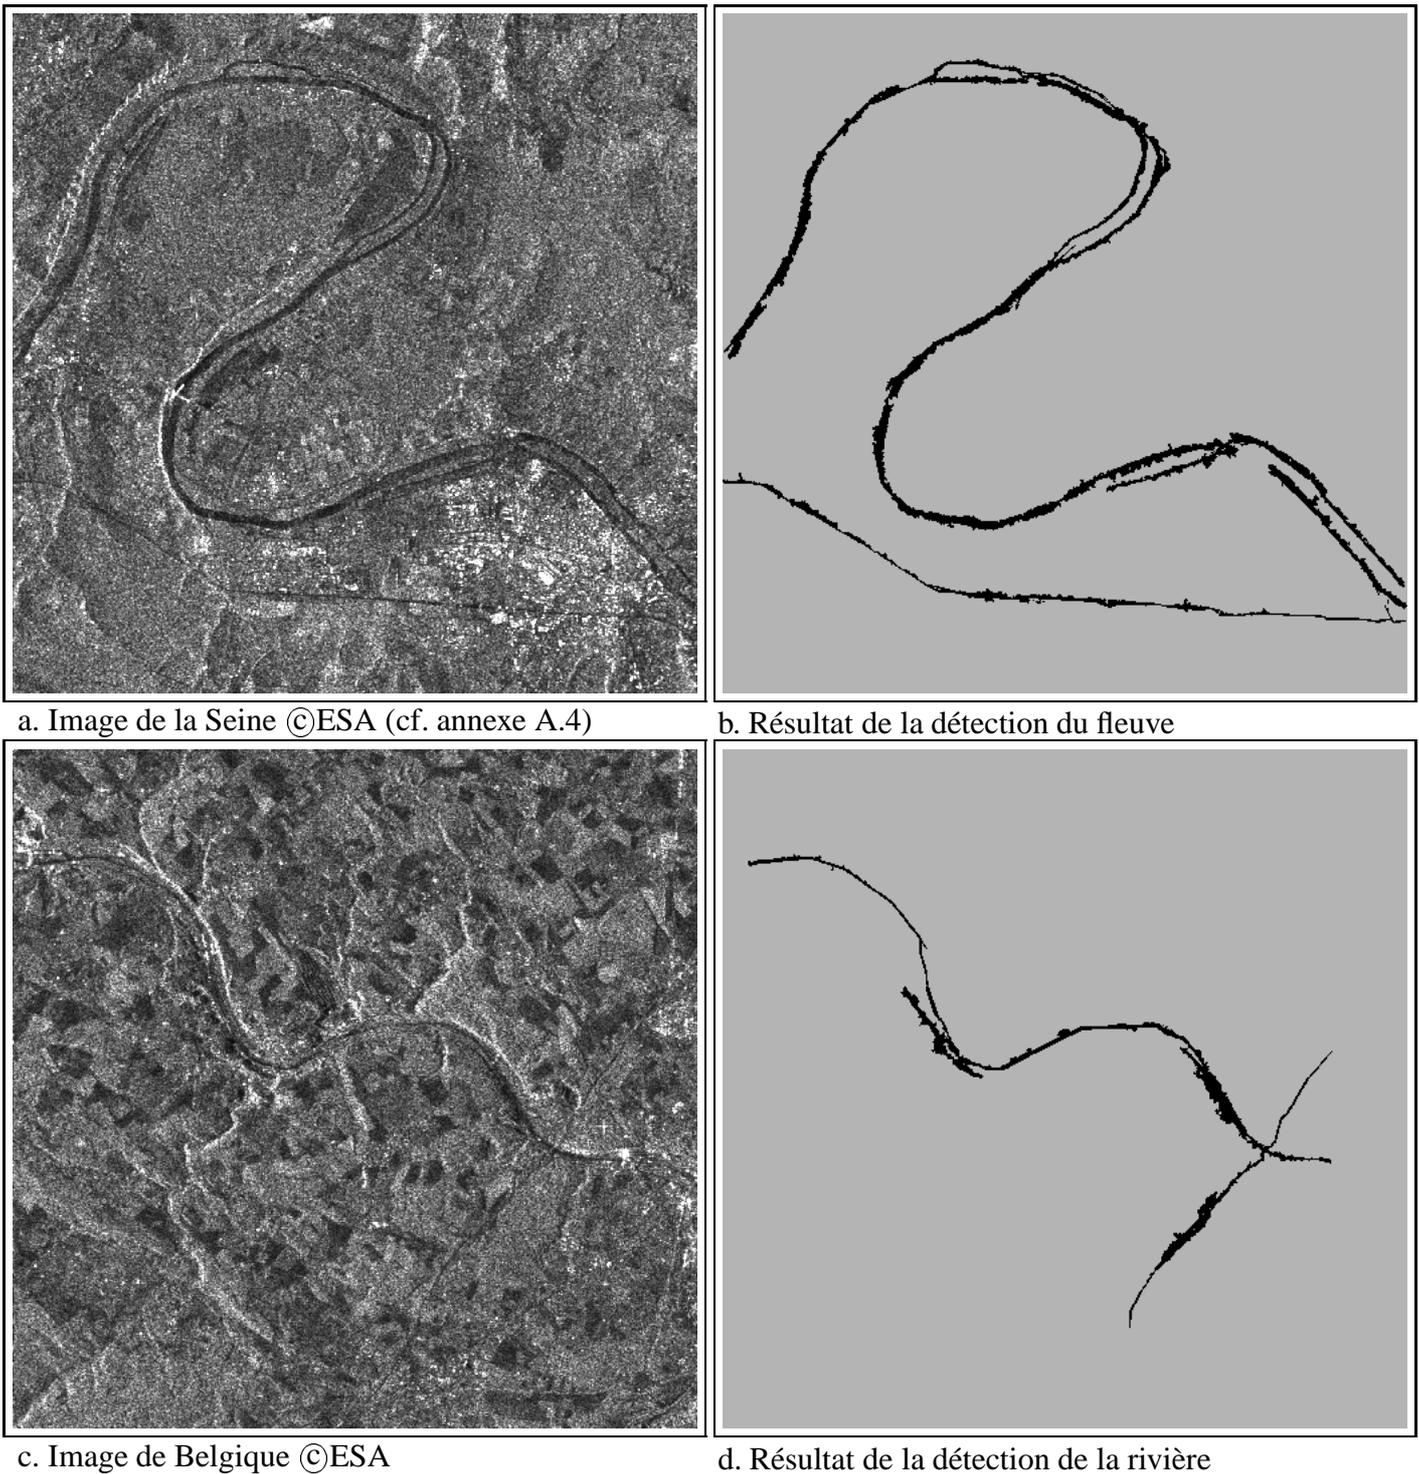


FIG. 4.20 – Détection de la Seine (en haut) et d'une rivière européenne (en bas)

par Lopes [Lope-93b]. Elle consiste à calculer le rapport entre la moyenne radiométrique d'une croix centrée en un pixel (qui représenterait la réponse en sinus cardinal bidimensionnel d'un réflecteur élémentaire) et le fond (fig.4.22). Lorsque le rapport est supérieur à 2, le pixel est supprimé de l'image qui sera traitée.

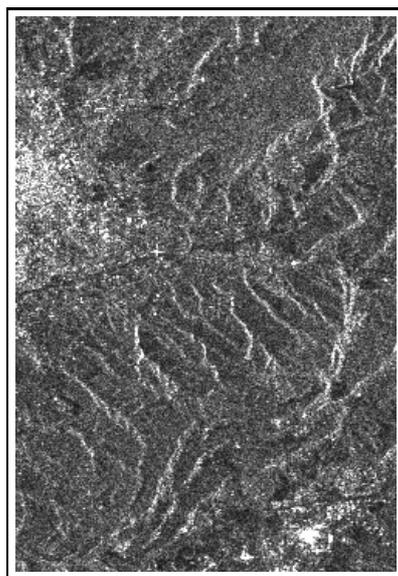


FIG. 4.21 – Image d'une partie de relief ©ESA

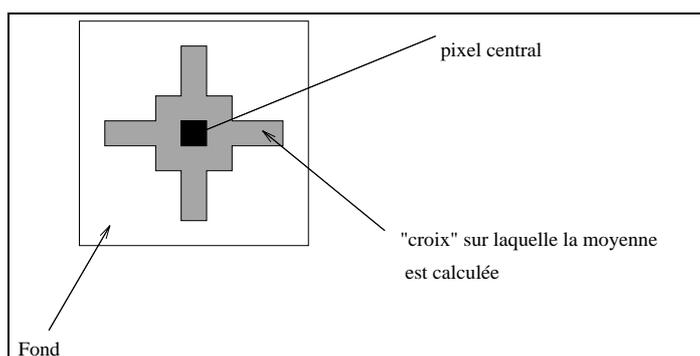


FIG. 4.22 – Détecteur de réflecteurs spéculaires proposé dans [Lope-93b]

Le résultat obtenu est une image binaire des structures et une image des directions.

Pour caractériser les zones où le relief est particulièrement important, ces structures sont regroupées en fonction de leur direction, de leur taille, et de leur proximité. La direction d'une structure est définie à l'aide des directions des pixels qui la constituent ; celles-ci sont classées selon leur fréquence d'apparition. La distance entre deux structures est définie par la distance entre leurs centres de gravité. Notons aussi que la méthode employée pour le regroupement nécessite la rupture des grandes structures en forme de "V" constituées de deux lignes de longueurs presque égales et de directions différentes.

La méthode utilisée est très simple et consiste à définir des structures "pivots" qui sont les plus grandes structures détectées. Les structures plus petites sont alors regroupées autour de ces pivots lorsqu'elles en sont proches et ont la même direction majoritaire. Une fois ces regroupements effectués, les groupes associés à des pivots distincts sont éventuellement fusionnés s'ils sont proches et de même direction.

Une autre méthode basée sur un champ de Markov adapté à la détection des structures linéaires est disponible dans [Tupi-96c] et [Trou-96] (voir également le chapitre 6).

Cette méthode plus générale développée pour l'interférométrie utilise l'image de cohérence ; elle a pour objectif de détecter les obstacles au développement de la phase (régions décorrélées, zones de lay-over, et pentes orientées vers le radar, sur lesquelles la phase est sous-échantillonnée).

### 4.3.3 Résultats

Les figures 4.23b et 4.23d montrent les résultats de la détection et du regroupement. Ces résultats sont suffisants pour donner une indication sur la localisation des zones de relief marqué, où la détection d'autres éléments du paysage (routes, zones industrielles) peut être perturbée.

## 4.4 Conclusion

Nous avons illustré dans ce chapitre l'utilisation des outils développés aux chapitres 2 et 3. Les principales structures linéiques du paysage ont été détectées dans l'une ou l'autre des trois applications : détection du réseau routier, du réseau hydrographique ou des lignes de fortes intensités des zones de relief. Les résultats obtenus ont été analysés sur différents paysages de difficultés variables, mettant en évidence les performances et les limites des méthodes que nous proposons pour la détection des objets linéiques.

Nous allons donc nous intéresser maintenant à d'autres éléments du paysage, non plus linéaires, mais sous forme de régions. C'est l'objet de la partie suivante.

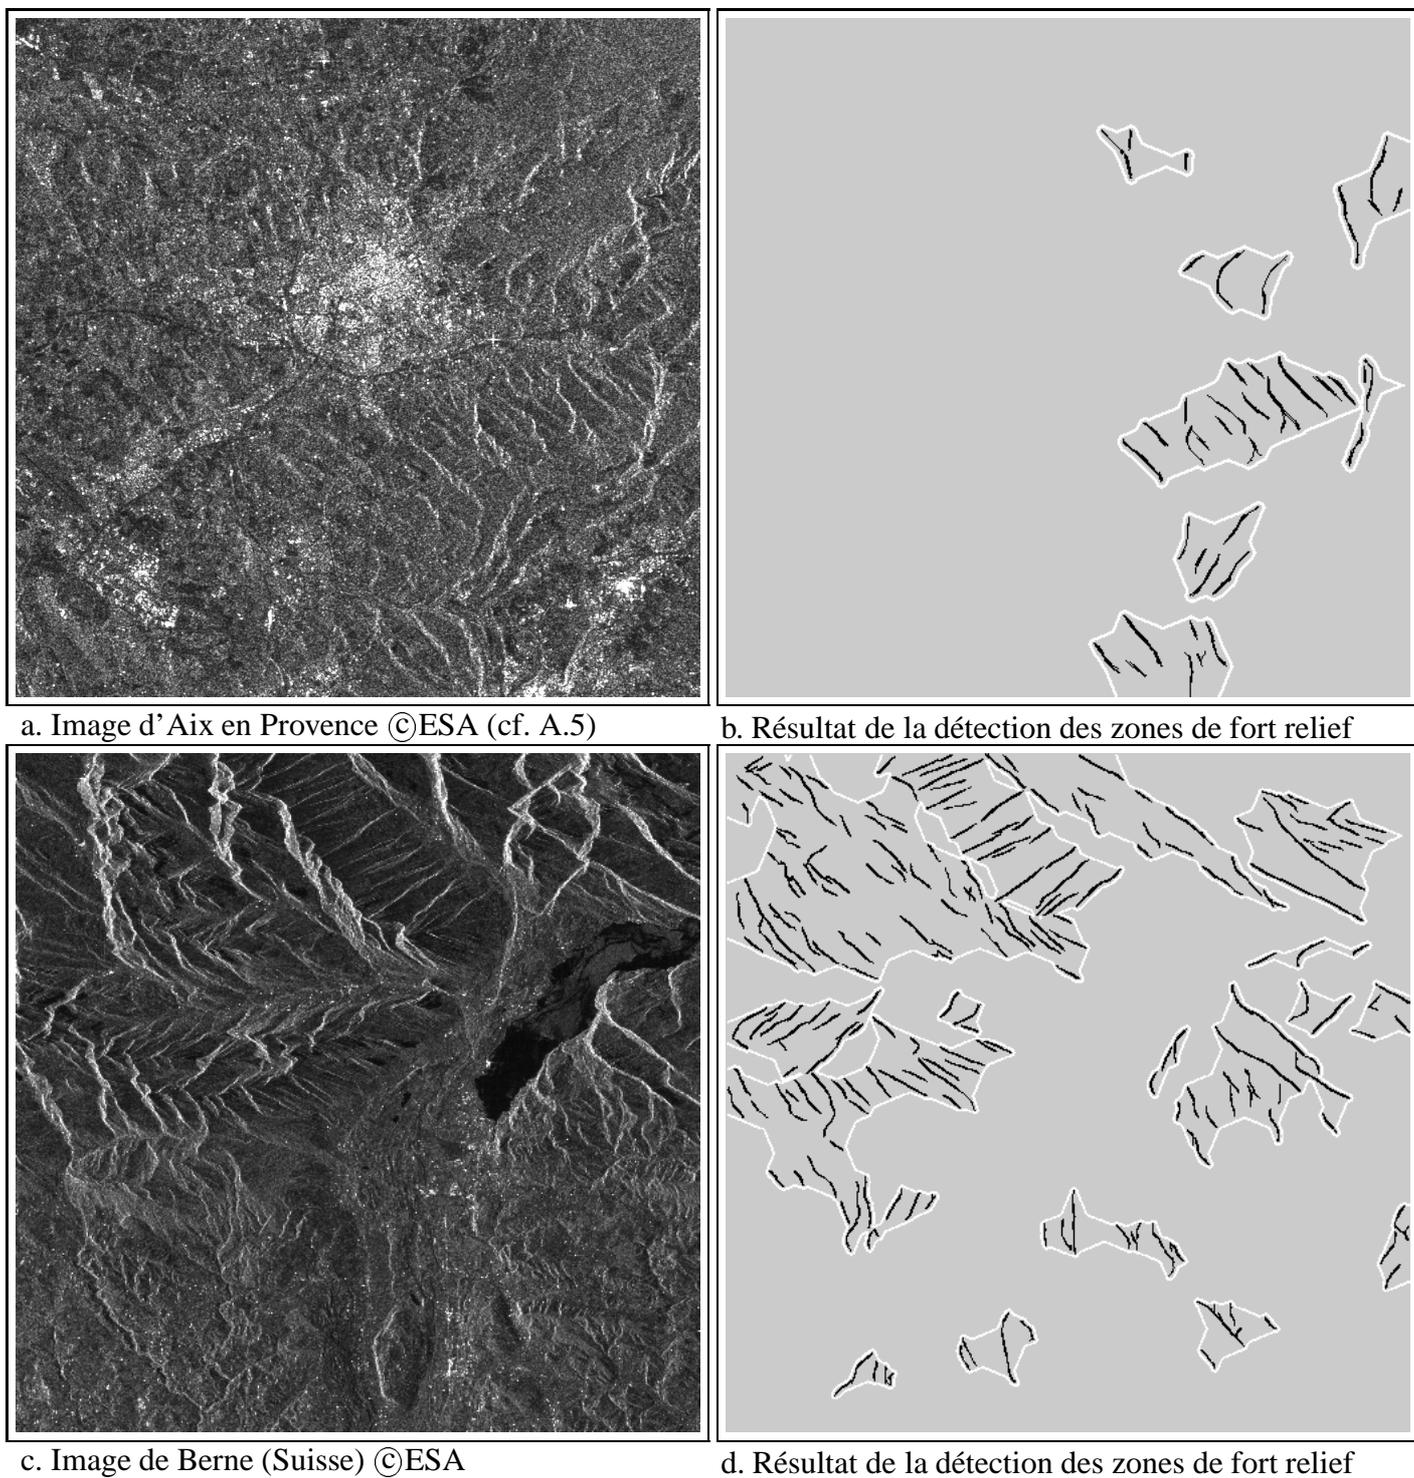


FIG. 4.23 – Détection des zones de relief sur la région d'Aix-en-Provence (en haut) et de Berne (en bas)

## **Deuxième partie**

### **Outils pour l'analyse de régions**



## Chapitre 5

# Le filtrage du chatoiement

*Ce chapitre présente quelques-uns des filtres les plus utilisés en imagerie radar pour supprimer le phénomène de chatoiement. Historiquement, les filtres proposés ont d'abord été ceux classiquement utilisés en traitement d'images (moyenne, médian). Puis, les statistiques locales du speckle ont été prises en compte. Pour finir, la scène sous-jacente (donc le coefficient de rétro-diffusion du sol) a été modélisée. Parallèlement, l'amélioration du calcul des statistiques locales a été accomplie en détectant la plus grande fenêtre homogène autour d'un pixel, ou en effectuant pendant le processus de filtrage des détections de contours, de lignes ou de points. Nous retraçons ces différentes étapes, puis nous proposons une méthode de régularisation itérative avec prise en compte des discontinuités.*

### 5.1 Présentation

Le problème du filtrage de speckle a mobilisé une énergie considérable et fait coulé beaucoup d'encre, si on se réfère aux nombreux articles qui paraissent tous les ans et depuis une vingtaine d'années sur ce sujet. Il faut dire que l'enjeu est de taille puisqu'un filtre idéal permettant de restaurer parfaitement la scène ramènerait le problème de l'analyse des images radar à celle des images optiques. Le filtrage a donc pour intérêt d'une part d'améliorer la qualité visuelle des images et, d'autre part, de se ramener à des outils développés depuis longtemps pour les images SPOT par exemple.

Le moyen le plus simple, déjà évoqué dans le chapitre 1, est d'utiliser des techniques de multi-vues, c'est à dire de moyennage de plusieurs pixels. Si on ne dispose que d'une seule image radar<sup>1</sup>, ce moyennage est effectué spatialement et le filtrage se fait au prix d'une perte de résolution proportionnelle au nombre de vues, ce qui en limite l'utilisation. D'autres méthodes ont donc été proposées qui conservent la résolution initiale. Plusieurs des filtres les plus utilisés pour le chatoiement des images radar sont présentés ci-dessous, ainsi qu'une nouvelle technique de régularisation avec une prise en compte des discontinuités.

Un filtre idéal doit répondre aux trois objectifs suivants :

- éliminer le chatoiement, donc lisser le plus possible les zones homogènes,

---

1. Le filtrage multi-temporel sera vu au §5.2.5.

- conserver et rehausser les structures de l'image (lignes, contours, très forts réflecteurs...),
- préserver la texture de la scène.

L'évaluation des performances d'un filtre est en pratique difficile. S'il est possible d'obtenir des critères objectifs pour les deux premières contraintes, comme le nombre de vues équivalent par exemple, en revanche le dernier point (qui nous paraît pourtant essentiel) est difficile à évaluer puisque nous ne connaissons pas a priori la texture de la scène.

Nous ne proposons pas ici une comparaison des filtres existants ([Dewa-90] [Lope-90] [Shen-96]), car celle-ci ne peut se faire à notre avis que pour une application donnée. Dans le cas des filtres mentionnés, nous nous contentons de remarques générales faites sur l'aspect visuel des images filtrées.

## 5.2 Quelques filtres classiquement utilisés

### 5.2.1 Les filtres non spécifiques

Nous rangeons dans cette catégorie les filtres qui ne prennent pas en compte les statistiques des images radar. Le plus simple est le filtre moyenne qui consiste à remplacer la valeur d'un pixel par la valeur moyenne de ses pixels voisins. Ce filtre revient à appliquer une technique de multi-vues effectuée spatialement tout en préservant artificiellement la résolution. Le voisinage considéré est généralement une fenêtre carrée donc choisie "à l'aveugle" en chaque pixel. Les zones homogènes sont bien lissées et le phénomène de chatoiement est réduit mais les contours sont rendus flous (fig.5.1b). Plus la taille de la fenêtre de traitement est grande, plus ces deux aspects se renforcent. Une solution pour les contours est l'utilisation du filtre médian ; ce filtre donne de bons résultats mais les zones homogènes sont moins bien lissées (fig.5.1c).

Un autre filtre ne prenant pas en compte les statistiques du chatoiement est le filtre de Crimmins [Crim-86], essentiellement géométrique, qui travaille sur la surface que constitue la radiométrie de l'image. Les résultats obtenus sont satisfaisants avec des contours bien préservés, mais la texture est généralement perdue ainsi que certaines réponses [Nezr-92].

### 5.2.2 Les filtres adaptatifs

Ces filtres prennent en compte les statistiques de l'image radar et donnent généralement des résultats supérieurs aux filtres précédents (à l'exception du filtre de Crimmins). Pour la plupart, ils évaluent localement des statistiques du premier ordre (moyenne et écart-type) qui sont ensuite intégrées dans la formule de filtrage. Le modèle utilisé est généralement un modèle multiplicatif de la forme  $I = RS$  où  $I$  est l'intensité de l'image,  $R$  la scène sous-jacente donc la réflectivité à reconstruire et  $S$  le chatoiement "normalisé" (voir §1.3.4). La relation entre les coefficients de variation de ces différentes grandeurs est :

$$\gamma_R^2 = \frac{\gamma_I^2 - \gamma_S^2}{1 + \gamma_S^2}$$

La formule de filtrage est alors obtenue en minimisant l'erreur quadratique moyenne (EQM) et en cherchant une solution linéaire :

$$R'_s = \bar{I}_s + k_s(I_s - \bar{I}_s)$$

où  $R'_s$  est l'estimation de la réflectivité, et l'indice  $s$  représente le pixel considéré ( $\bar{I}_s$ , et  $\gamma_{I_s}$  sont calculées sur un voisinage centré sur le pixel  $s$ ).

L'approximation  $(R - \langle R \rangle)(S - \langle S \rangle) \approx 0$  donne le filtre de Lee [Lee-80] [Lee-81a] [Lee-81b] avec :

$$k_s = 1 - \frac{\gamma_S^2}{\gamma_{I_s}^2}$$

Sans cette approximation, la valeur de  $k_s$  obtenue est (filtre de Kuan [Kuan-85] [Kuan-87]) :

$$k_s = \frac{1 - \frac{\gamma_S^2}{\gamma_{I_s}^2}}{1 + \gamma_S^2}$$

Un résultat est montré sur la figure 5.1d.

Les comportements de ces deux filtres très utilisés en imagerie radar sont proches. Sur une zone très homogène, on a  $\gamma_I \approx \gamma_S$  et donc  $k_s = 0$ , ce qui implique  $R'_s = \bar{I}_s$ . La valeur du filtre sur une zone homogène est simplement la moyenne locale. En revanche, sur une zone très hétérogène (à proximité d'une discontinuité par exemple), on a  $\gamma_I \gg \gamma_S$ , donc  $k_s = 1$  pour le filtre de Lee (et  $\frac{1}{1+\gamma_S^2}$  pour le filtre de Kuan)<sup>2</sup>. Ainsi  $R'_s = I_s$  (respectivement  $R'_s = \frac{1}{1+\gamma_S^2}I_s + \frac{\gamma_S^2}{1+\gamma_S^2}\bar{I}_s$ ) et l'action de moyennage est interrompue ou limitée sur ce genre de zones où la meilleure estimation de la réflectivité est la radiométrie même du pixel. Les filtres logarithmiques s'appuient également sur les statistiques locales de l'image mais après transformation logarithmique de celle-ci [Arse-84] [Arse-86] [Yan-86]. Elle a l'avantage de rendre le bruit additif, cas pour lequel des techniques classiques peuvent être appliquées. Arsenault et Levesque effectuent par exemple un filtrage adaptatif [Lee-80] puis retransforment l'image exponentiellement pour obtenir le résultat final (fig.5.1e).

Des améliorations ont été apportées à ces différents filtres (et au filtre de Frost présenté dans le paragraphe suivant) par Lopes, à l'aide d'une étude de leurs comportements en fonction du coefficient de variation [Lope-90].

### 5.2.3 Les filtres adaptatifs avec modélisation de la scène

De nombreux filtres modélisent la réflectivité de la scène à restaurer. C'est le cas du filtre de Frost [Fros-82] également très répandu, qui modélise la scène par un processus auto-régressif avec une fonction d'auto-corrélation exponentielle. Sous ces hypothèses, le filtre minimisant l'erreur quadratique moyenne peut être déduit. Son expression dépend là encore du coefficient de variation calculé localement.

2. Rappelons que  $\gamma_S \approx 0,3$  en 3-vues (cf. chapitre 1).

Plusieurs approches modélisent la densité de probabilité de la scène  $R$ . Dans ce cas, le critère souvent utilisé est le MAP (Maximum A Posteriori), ce qui signifie qu'on cherche à maximiser la probabilité a posteriori  $p(R|I)$ . En utilisant la loi de Bayès et en choisissant  $p(R)$ , une expression de  $R'$  est déduite. On peut trouver dans la littérature plusieurs choix pour  $p(R)$ , comme il a déjà été signalé dans le §1.3.4 [Lewi-83]. Dans une optique de filtrage, Kuan propose par exemple une modélisation gaussienne [Kuan-87]. Nezry fait une étude systématique des différentes lois possibles et de leur adéquation à la scène [Nezr-92]. Une formule de filtrage est obtenue dans chaque cas. On a vu au §1.3.4 qu'une densité de probabilité bien adaptée est la distribution gamma. On obtient dans ce cas le filtre dit "Gamma-MAP" qui est donné en un pixel pour une image d'intensité par :

$$R'_s = \frac{\gamma_R^2}{2} \left( \overline{T}_s \left( \frac{1}{\gamma_R^2} - L - 1 \right) + \sqrt{\overline{T}_s^2 \left( \frac{1}{\gamma_R^2} - L - 1 \right)^2 + 4 \frac{1}{\gamma_R^2} L I_s \overline{T}_s} \right)$$

où  $L$  est le nombre de vues.

Hillion et Boucher ont proposé un filtre linéaire généralisé, c'est à dire qu'ils cherchent un meilleur estimateur (au sens de l'EQM) de la forme  $aI^t + b$  [Hill-88] [Hill-91]. La valeur de  $t$  pour laquelle l'EQM est minimale donne le filtre optimal. Sa forme varie avec la distribution supposée pour la réflectivité et pour le speckle. Si aucune hypothèse n'est faite pour la distribution de  $R$ , une version approchée du filtre généralisé est utilisée.

On trouvera également dans la thèse de Sery [Sery-97] une étude très complète des solutions obtenues pour d'autres critères d'estimation aussi bien dans le cas mono-canal que polarimétrique [Lope-97].

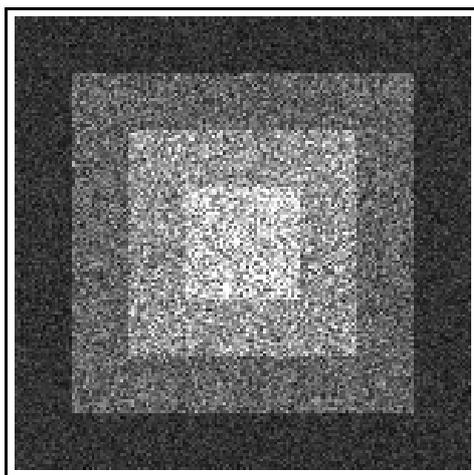
Toutes ces modélisations font généralement intervenir la densité de probabilité de  $R$  mais tiennent rarement compte de la corrélation des pixels. L'intégration de ce facteur donne une formule de filtrage relativement complexe puisqu'elle fait intervenir les matrices d'auto-corrélation [Kuan-87].

## 5.2.4 L'amélioration du calcul des statistiques

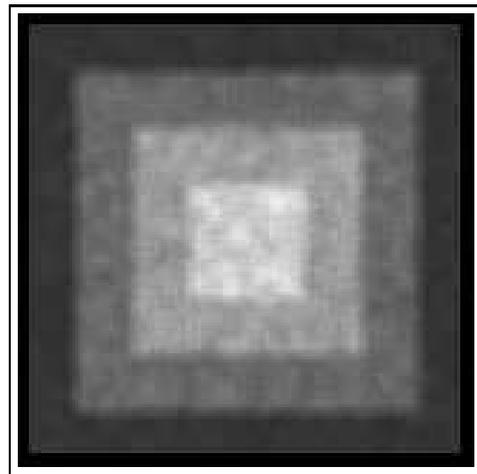
La taille et la forme de la fenêtre de calcul des statistiques sont des paramètres primordiaux pour tous les filtres précédents. Celles-ci doivent répondre à deux contraintes antagonistes : d'une part, il faut que le calcul s'effectue sur des pixels appartenant à la même région physique que le pixel considéré ; d'autre part, il faut que le nombre de pixels utilisés pour ce calcul soit le plus grand possible. En effet, plusieurs études ont montré que le nombre de pixels nécessaires à une évaluation fiable des statistiques d'une région est très élevé (de l'ordre de 300 pixels pour le coefficient de variation) [Laur-89] [Goui-96]<sup>3</sup>. Ces tailles sont en pratique prohibitives et entraînent la prise en compte de pixels d'autres régions si les fenêtres sont de forme carrée.

Lee [Lee-81b] et Kuan [Kuan-85] préconisent l'utilisation de détecteurs de contours pour vérifier localement l'homogénéité d'une fenêtre de traitement. Mais cela permet seulement de répondre à la première contrainte.

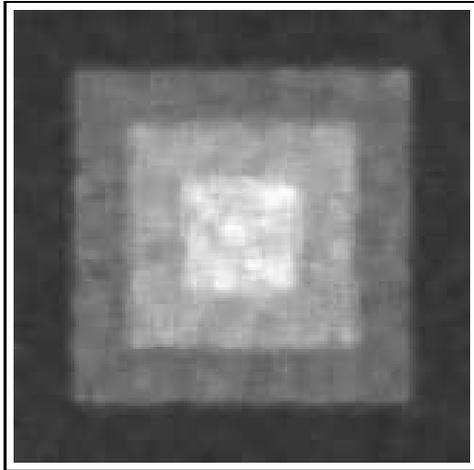
3. On retrouve ces résultats dans l'étude des probabilités de fausses alarmes des détecteurs D1 et D2 ; celles-ci diminuent lorsque le nombre de pixels pris en compte augmente.



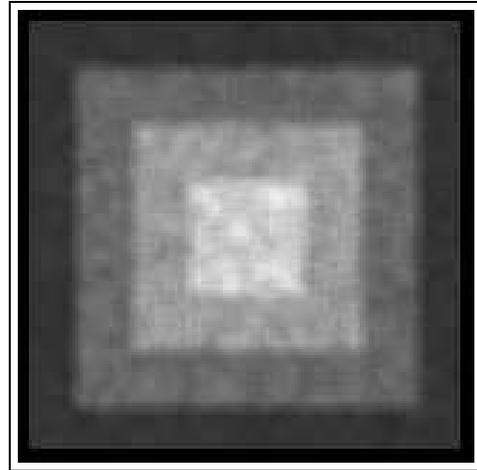
a. Image synthétique originale



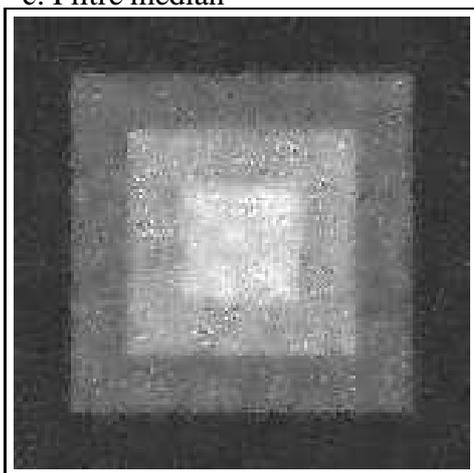
b. Filtre moyenne



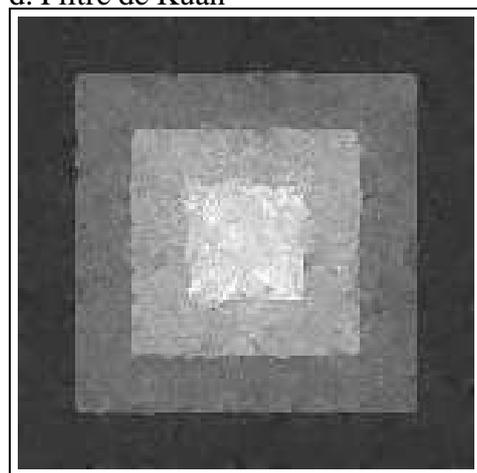
c. Filtre médian



d. Filtre de Kuan



e. Filtre d'Arsenault et Levesque



f. Filtre de Wu et Maître modifié combiné au filtre de Kuan

FIG. 5.1 – Application de quelques filtres (lorsqu'une fenêtre de traitement est utilisée, elle est de taille  $7 \times 7$ )

En revanche, Wu et Maître ont proposé une solution permettant de prendre en compte les deux aspects du problème [Wu-92]. Elle consiste à rechercher en un pixel la plus grande fenêtre homogène à laquelle appartient ce pixel. La méthode proposée est une technique de croissance de régions, au départ de forme carrée. La variation de l'écart-type  $\Delta\sigma$  au cours de la croissance permet de distinguer quatre cas :

- si l'écart-type diminue significativement (par rapport à un seuil), le pixel est un réflecteur spéculaire et la croissance est arrêtée ; les statistiques sont calculées sur la fenêtre initiale ;
- si l'écart-type augmente significativement, alors le pixel est proche d'un contour ; la position du contour est détectée et la croissance a lieu dans la direction opposée au contour ; elle s'arrête lorsque toute croissance augmente l'écart-type et les statistiques sont calculées sur la plus grande fenêtre obtenue ;
- si  $\Delta\sigma$  n'est pas particulièrement élevé mais que l'écart-type initial l'est, le pixel est sur un contour ; le déroulement des opérations est le même que précédemment ;
- si  $\Delta\sigma$  est faible et que l'écart-type initial l'est également, le pixel appartient à une zone homogène ; la fenêtre est agrandie jusqu'à ce que plus aucune croissance ne soit possible ou jusqu'à ce qu'une taille limite soit atteinte.

Dans tous les cas, le calcul des statistiques se fait sur la plus grande fenêtre possible autour du pixel. Le filtrage à proprement parler est ensuite réalisé par un filtre de Kuan, mais d'autres filtres pourraient être utilisés.

Le paramètre choisi pour tester l'homogénéité des zones n'est cependant pas bien adapté aux images radar. En effet, comme il a déjà été mentionné, l'écart-type d'une région augmente avec sa radiométrie. Par conséquent, les tailles de fenêtres maximales obtenues sur des régions homogènes sombres et brillantes seront différentes. Le filtrage dépendra donc de la radiométrie des régions. Aussi proposons nous de remplacer l'écart-type par le coefficient de variation (§1.3.2) ce qui apporte une amélioration significative. Notons que les résultats obtenus dépendent fortement des fenêtres sur lesquelles sont calculées les statistiques. En effet, le filtre utilisé a peu d'influence puisqu'on se ramène souvent à une zone homogène, cas dans lequel la majorité des filtres sont équivalents à un moyennage (fig.5.1f).

Une autre manière de résoudre le problème est de choisir de grandes tailles de fenêtres ( $11 \times 11$  par exemple), mais de coupler au filtrage des détecteurs de contours, de lignes et de réflecteurs spéculaires pour les préserver. C'est l'approche adoptée par Lopes *et al.* qui utilisent un filtre Gamma-MAP et effectuent parallèlement ces détecteurs [Lope-93b].

Nous tenons également à faire ici une remarque générale. Il est souhaitable de travailler sur les images 16 bits lorsqu'elles sont disponibles. En effet, les statistiques et, surtout, le coefficient de variation peuvent être perturbés lors du passage en 8 bits [Goui-96].

### 5.2.5 Le filtrage multi-temporel

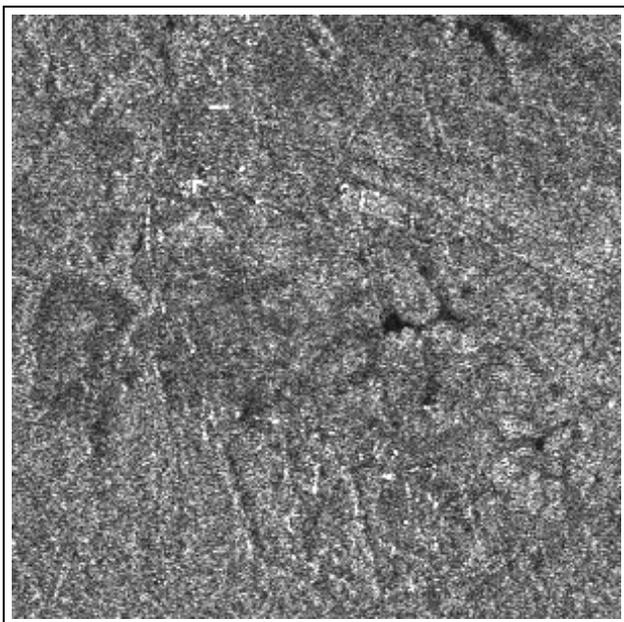
Nous nous sommes jusqu'à présent intéressés aux techniques de filtrage qui travaillent sur une unique image radar dont elles améliorent la lisibilité. Une autre optique consiste à utiliser plusieurs images d'une même région et à les fusionner. L'information disponible étant dans ce cas bien supérieure à celle fournie par une image radar seule, nous traitons à

part cette approche généralement nommée filtrage multi-temporel car les images utilisées sont acquises à des dates différentes.

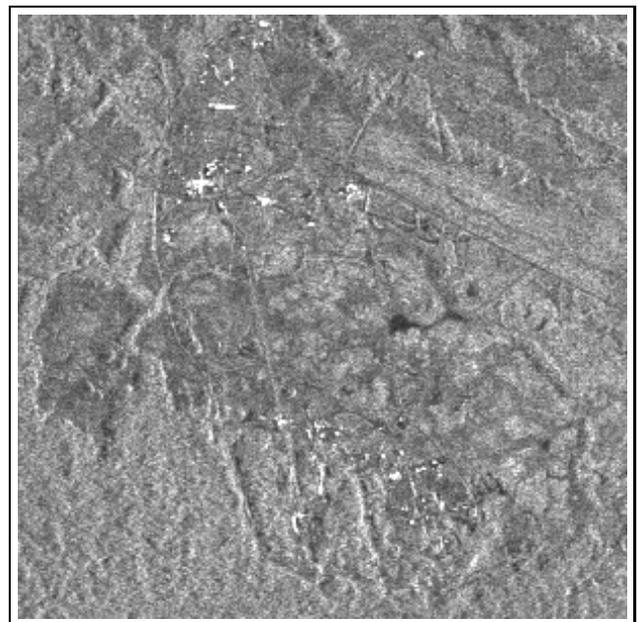
En pratique, c'est la technique la plus prometteuse quant au filtrage, mais également la plus coûteuse. En effet, elle utilise les différentes images comme des vues incohérentes et applique une méthode de multi-vues. Les images sont généralement obtenues à des dates différentes et une simple opération de moyennage n'est parfois pas adaptée aux variations temporelles qui interviennent. Néanmoins, les résultats sont spectaculaires (figure 5.2).

Pour améliorer cette technique et tenir compte des variations, il est bon de ne moyennner les images que lorsqu'elles contiennent la même information. Une façon de mesurer la redondance des informations est d'utiliser la corrélation entre les différentes vues [Brun-94] [Brun-96]. Au lieu d'un unique résultat, autant d'images améliorées (filtrées) que d'images initiales sont obtenues.

Le principal inconvénient de cette technique est qu'il faut disposer de plusieurs images radar de la même zone, ce qui est d'un coût non négligeable pour l'utilisateur.



a. Image de la base de Kourou ©ESA



b. Moyennage de six images prises à des dates différentes

FIG. 5.2 – Exemple de filtrage multi-temporel

## 5.3 Régularisation avec prise en compte des discontinuités

Ce travail a été mené conjointement avec Marc Sigelle et initialisé par le stage de DEA d'Amar Chkeif [Chke-95] (implantation des algorithmes ARTUR ET LEGEND proposés par Charbonnier [Char-94]).

### 5.3.1 Introduction

Nous avons déjà abordé dans le chapitre 4 des techniques markoviennes. Il s'agit ici de les utiliser à des fins de restauration, pour supprimer le chatolement présent sur les images radar. Nous nous sommes intéressés aux méthodes avec prise en compte des discontinuités [Gema-84] [Blak-87] [Geig-91] [Gema-92] [Bedi-94] [Char-94] que nous avons cherché à adapter aux images radar.

Le problème est donc la recherche d'une image de départ  $f$  (sans chatolement) dont nous connaissons une observation  $p$  bruitée (l'image radar). Si nous choisissons un critère de Maximum A Posteriori (MAP), nous cherchons une solution  $f$  telle que la probabilité  $Pr(F = f | P = p)$  soit maximale. En utilisant le théorème de Bayès, le problème se ramène à la minimisation de l'énergie  $U(f)$  (cf. §3.2), avec :

$$\begin{aligned} U(f) &= -\log Pr(F = f | P = p) = U_1(f) + U_2(f) \\ \text{avec } U_1(f) &= \sum_{s \in S} -\log Pr(P_s = p_s | F_s = f_s) \\ \text{et } U_2(f) &= \sum_{c \in \mathcal{C}} U_c(f) \end{aligned}$$

où  $S$  représente l'ensemble des sites (les pixels de l'image ici) et  $\mathcal{C}$  l'ensemble des cliques.

L'écriture de  $U_1(f)$  nécessite l'indépendance des sites<sup>4</sup> et suppose que la valeur de l'observation en un site ne dépende que de la donnée initiale en ce site. Quant à  $U_2(f)$ , elle exprime un a priori imposé à la solution recherchée permettant de réduire l'espace de recherche et de rendre le problème bien-posé. Elle dépend des cliques et des potentiels qui leur sont associés.

Le choix de l'a priori imposé est important puisqu'il conditionne la solution. Nous allons ici supposer que les solutions cherchées sont constituées de zones homogènes séparées par des bords francs. Cette contrainte nous permet de nous limiter aux cliques composées par des couples de pixels voisins (le voisinage pouvant être 4- ou 8-connexe). Ainsi, le terme contextuel de l'énergie s'écrit :

$$U_2(f) = \sum_{(r,s) \in \mathcal{C}} U_{rs}(f) = \lambda \sum_{(r,s) \in \mathcal{C}} \Phi(f_r, f_s)$$

où  $\lambda$  est un coefficient de lissage positif permettant de pondérer l'influence du terme contextuel par rapport au terme d'attache aux données  $U_1(f)$ . Des hypothèses plus réalistes peuvent être modélisées en utilisant des cliques d'ordre plus élevé. Généralement, la contrainte s'exprime sur le gradient de l'image et on choisit  $\Phi(f_r, f_s) = \phi(f_r - f_s)$  :

$$U_2(f) = \sum_{(r,s) \in \mathcal{C}} U_{rs}(f) = \lambda \sum_{(r,s) \in \mathcal{C}} \phi(f_r - f_s) \quad (5.1)$$

Un des objectifs du filtrage est de préserver les discontinuités entre les différentes régions de l'image et il peut s'exprimer dans le choix de la fonction  $\phi$  [Gema-92]. Une approche duale est l'introduction d'un processus bord explicite [Gema-84].

4. Comme il a été montré au chapitre 1, cette hypothèse n'est en toute rigueur pas vérifiée sur les images ERS-1 §1.3.5.

Le théorème suivant, fondé sur la transformation de Legendre, permet d'établir une équivalence entre les deux approches sous certaines conditions. Celui-ci s'énonce en effet :

**Théorème :** Soit  $\phi$  et  $\mathcal{H}$  deux fonctions définies sur  $R^+$  telles que  $\mathcal{H}$  soit positive et croissante, et  $\phi$  strictement concave croissante, et  $L$  et  $M$  définis par :

$$L = \lim_{x \rightarrow \infty} \phi'(x) \text{ et } M = \lim_{x \rightarrow 0^+} \phi'(x)$$

Alors :

- il existe une fonction  $\psi$  strictement convexe et décroissante, définie de  $[L, M]$  dans  $[\alpha, \beta]$ , telle que :

$$\phi(\mathcal{H}(x)) = \inf_{L \leq b \leq M} (b\mathcal{H}(x) + \psi(b)) \text{ avec}$$

$$\alpha = \lim_{x \rightarrow +\infty} \phi(x) - x\phi'(x) \text{ et } \beta = \lim_{x \rightarrow 0^+} \phi(x) - x\phi'(x)$$

- pour tout  $x$ , la valeur de l'infimum est atteinte en  $b_x = \phi'(\mathcal{H}(x)) \geq 0$

Par conséquent, la prise en compte des discontinuités dans l'image lors de la restauration peut se faire : ou bien en choisissant des fonctions  $\phi$  et  $\mathcal{H}$  répondant aux contraintes précédentes avec  $L = 0$  et  $M = 1$  (correspondant à  $b_x \in [0, 1]$ ), ou bien en introduisant explicitement le processus bord  $b$  [Char-94]. Nous choisissons ici une formulation explicite (cf. 5.1) :

$$U_2(f, b) = \sum_{(r,s) \in \mathcal{C}} b_{rs} \mathcal{H}(f_r - f_s) + \sum_{(r,s) \in \mathcal{C}} \psi(b_{rs})$$

où  $b_{rs}$  représente le processus bord entre les sites  $r$  et  $s$ . En pratique, ce processus permet d'interrompre la régularisation de la solution lorsqu'un bord a été détecté entre les sites  $r$  et  $s$  (dans ce cas  $b_{rs}$  est faible, proche de 0) et, au contraire, de la maintenir lorsque les deux sites appartiennent à la même zone bruitée ( $b_{rs}$  proche de 1).

Nous avons donné une formulation générale du théorème proposé par Geman et Reynolds dans [Gema-92], puis sous une autre forme par Charbonnier [Char-94]. Dans les deux cas, la fonction  $\mathcal{H}$  utilisée est la fonction quadratique  $\mathcal{H}(x) = x^2$ , bien adaptée à un bruit blanc gaussien additif. Ce théorème permet de transformer une énergie non convexe préservant les discontinuités de façon implicite en une énergie avec processus bord explicite et convexe, pour faciliter l'optimisation. Dans le cas des images radar, d'autres fonctions pourraient se révéler plus appropriées. La démonstration de ce théorème dans le cas de  $\mathcal{H}(x) = x^2$  donnée dans l'annexe B de la thèse de Charbonnier [Char-94] reste en tous points valable dans le cas d'une fonction  $\mathcal{H}$  quelconque positive croissante sur  $R^+$ , aussi ne la donnons nous pas ici.

Les algorithmes déterministes mis en œuvre pour trouver le minimum de  $f$  consistent alors en une alternance de minimisations en  $f$  et en  $b$ . En notant  $f^{(n)}$  et  $b^{(n)}$  les valeurs prises à l'étape  $n$ , le déroulement des différentes étapes est le suivant :

- initialisation de  $f$  et  $b$  par  $f^{(0)}$  et  $b^{(0)}$ ,

– répétition des étapes suivantes jusqu'à convergence :

1.  $b^{(n+1)} = \arg \min_b U(f^{(n)}, b)$
2.  $f^{(n+1)} = \arg \min_f U(f, b^{(n+1)})$

L'initialisation est choisie arbitrairement : il peut s'agir de l'image originale (c'est le cas ici), d'une image constante, d'une image aléatoire, etc. Pour l'étape 1, à  $f$  fixé, le théorème précédent nous donne l'expression du processus bord :

$$b_x = \phi'(\mathcal{H}(x)) \quad (5.2)$$

Puis, pour l'étape 2 à  $b$  fixé,  $f$  est estimé de façon itérative. La méthode choisie est la méthode de Newton-Raphson, c'est à dire que si  $f_s^{(n)}$  est la valeur prise par  $f$  au site  $s$  et à l'étape  $n$ , alors  $f_s^{(n+1)}$  est obtenue par :

$$f_s^{(n+1)} - f_s^{(n)} = -\omega \frac{\partial U}{\partial f_s} \text{ avec } \omega = \frac{1}{\frac{\partial^2 U}{\partial f_s^2}}$$

Le nombre d'itérations nécessaire à la convergence de  $f$  est effectué (le critère d'arrêt est un taux de variation d'une itération à la suivante inférieur à un seuil donné) ; puis le processus recommence à l'étape 1 et ainsi de suite.

Fondé sur ces résultats, notre travail a essentiellement porté sur les possibilités d'adaptation de ces algorithmes à la restauration des images radar. Pour conserver la dynamique de 16 bits des images radar, nous avons utilisé des algorithmes déterministes, plus rapides que les algorithmes stochastiques<sup>5</sup>. De plus, des choix appropriés ou des modifications sont à faire à deux niveaux : au niveau de  $U_1(f)$  et de la densité de probabilité à utiliser ; et au niveau de  $U_2(f, b)$ , et du processus bord. Nous avons vu que le théorème précédent permettait de calculer  $b_{rs}$  entre deux sites par  $\phi'(\mathcal{H}(f_r - f_s))$ . Par conséquent, le processus bord dépend de la différence radiométrique entre  $r$  et  $s$ . Ainsi, lorsque  $f_r - f_s$  est faible,  $b_{rs}$  doit être proche de 1 (pas de contour) et, dans le cas contraire, proche de 0 (présence d'un contour). Cette expression fondée sur le gradient n'est pas compatible avec la statistique des images radar et donnerait des lissages très différents suivant la radiométrie moyenne des régions (cf. §2.1). Nous proposons donc de calculer  $b_{rs}$  en remplaçant dans l'équation 5.2,  $x = f_r - f_s$  par un détecteur de contours adapté aux images radar. Nous étudions également l'utilisation d'une fonction  $\mathcal{H}$  plus appropriée aux images radar.

La partie suivante détaille le processus bord que nous proposons d'utiliser. Les différents cas que nous avons étudiés sont ensuite développés et finalement une comparaison des résultats obtenus est donnée. Des prolongements possibles à ces travaux sont également évoqués.

### 5.3.2 Définition du processus bord $b_{rs}$ sur les images radar

L'utilisation du gradient pour le calcul du processus bord n'étant pas adapté, nous proposons donc de calculer  $b_{rs}$  par  $\phi'(\mathcal{H}(d_{rs}))$ , où  $d_{rs}$  est un détecteur de contours adapté aux

5. Un tirage aléatoire sur 65 536 niveaux de gris (correspondant à la dynamique 16 bits) est très long.

images radar. Le détecteur que nous avons utilisé est Dc1 (détecteur rapport) présenté au chapitre 3. Ainsi, si  $Re(r)$  et  $Re(s)$  sont deux régions définies par les sites  $r$  et  $s$  pour une clique donnée (horizontale, verticale ou diagonale) :

$$\overline{d_{rs}} = r_{Re(r)Re(s)} = 1 - \min\left(\frac{\overline{A_{Re(r)}}}{\overline{A_{Re(s)}}}, \frac{\overline{A_{Re(s)}}}{\overline{A_{Re(r)}}}\right)$$

Les régions sont de taille  $5 \times 2$  pixels seulement pour essayer de préserver les détails fins (fig.5.3).

Nous pouvons également définir un détecteur ponctuel par :

$$d_{rs} = 1 - \min\left(\frac{A_r}{A_s}, \frac{A_s}{A_r}\right)$$

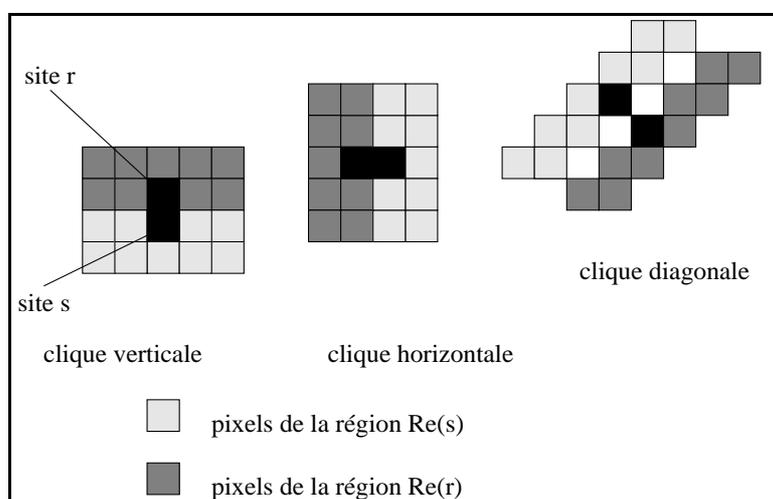


FIG. 5.3 – Régions utilisées pour le calcul de  $\overline{d_{rs}}$

Généralement, on introduit un paramètre  $\delta$  permettant de contrôler la hauteur des discontinuités qu'on veut détecter et le terme  $f_r - f_s$  est remplacé par  $\frac{f_r - f_s}{\delta}$ . Le même paramètre est utilisé ici, les réponses  $d_{rs}$  supérieures à  $\delta^*$  étant considérées comme significatives ( $\delta^* = 0,13$  cf. §2.2 dans le cas des contours). Notons que, contrairement au gradient,  $d_{rs}$  est toujours positif.

### 5.3.3 Méthodologie de l'étude

Nous proposons plusieurs expérimentations pour analyser le comportement des techniques de restauration avec prise en compte des discontinuités appliquées aux images radar.

Nous allons tester plusieurs configurations et analyser les résultats obtenus dans les différents cas, en comparant particulièrement la qualité de la restauration dans les zones sombres et claires. Des choix peuvent être faits à trois niveaux différents :

- Choix de la densité de probabilité : nous avons testé des distributions gaussiennes et gammas généralisées, la seconde étant plus adaptée aux statistiques réelles de l'image radar.

- Choix de la fonction de régularisation: le choix usuel est celui d'une fonction  $\mathcal{H}$  quadratique. Nous montrerons que d'autres fonctions peuvent être utilisées dans le cas des images radar.
- Choix du processus bord: la bonne expression est  $b_{rs} = \phi'(\mathcal{H}(\frac{u}{\delta}))$ , où  $u$  est la variable intervenant dans l'énergie  $U_2$ . Nous proposons de réaliser des expérimentations en remplaçant  $b_{rs}$  par  $b_{rs}^* = \phi'(\mathcal{H}(\frac{d_{rs}}{\delta^*}))$ . Cette modification nous fait bien sûr sortir des cadres théoriques des théorèmes de Geman et Reynolds [Gema-92] ou de Charbonnier [Char-94]. Par conséquent, nous n'avons aucune preuve de convergence des algorithmes dans ce cas précis, hormis les résultats empiriques des expérimentations. De plus nous proposons d'estimer le processus bord en utilisant des valeurs moyennes de l'amplitude dans le gradient ou dans le rapport. Lorsque l'estimation aura été faite de cette façon, nous noterons  $b_{rs}$  par  $\overline{b_{rs}}$  et  $b_{rs}^*$  par  $\overline{b_{rs}^*}$ .

Le tableau 5.1 récapitule les différentes combinaisons que nous avons testées, et qui sont détaillées dans les sections suivantes.

distribution	gaussienne		gamma généralisée		
fonction de rég.	$x = G_{rs}, \mathcal{H}(x) = x^2$		$x = G_{rs}, \mathcal{H}(x) = x^2$	$x = R_{rs}, \mathcal{H}(x) = x + \frac{1}{x} - 2$	
proc. bord	$b_{rs}$	$b_{rs}^*$	$b_{rs}$	$b_{rs}^*$	$b_{rs}$
section	5.3.4a	5.3.4b	5.3.5a	5.3.5b	5.3.6

TAB. 5.1 – Résumé des tests effectués et des sections correspondantes, en notant  $G_{rs} = f_r - f_s$  and  $R_{rs} = \frac{f_r}{f_s}$ .

Pour toutes ces configurations, des tests sont effectués en utilisant des estimations ponctuelles et par moyennage pour le processus bord. En ce qui concerne la fonction  $\phi$ , nous avons utilisé la fonction proposée par Geman et McClure [Gema-85]  $\phi(x) = \frac{x}{1+x}$  dans tous les tests. Les résultats du filtrage sont montrés sur la mire 3-vues synthétique<sup>6</sup> de la figure 5.1a. Les remarques qui sont faites sur les résultats de la restauration sont aussi déduites de l'observation des processus bords finals. Lorsque ceux-ci sont montrés, les processus bords dans les huit directions sont superposés, d'où des contours épais. Nous avons également utilisé pour les tests un morceau d'image provenant de la scène ERS-1 sur les Pays-Bas. Cette image a l'avantage de représenter du parcellaire marqué avec des structures linéaires fines qui permettent de mesurer, ne serait ce que visuellement, les effets du filtrage sur les contours et les lignes.

### 5.3.4 Distribution gaussienne et fonction $\mathcal{H}$ quadratique

Nous allons dans ce premier cas supposer que la densité de probabilité du chatoiement est gaussienne, et que  $\mathcal{H}$  est la fonction quadratique. Dans ce cas, on obtient (en intégrant dans  $\lambda$  le facteur multiplicatif):

$$U(f, b) = \sum_{s \in S} (p_s - f_s)^2 + \lambda \sum_{c \in \mathcal{C}} b_{rs} (f_s - f_r)^2 + \sum_{c \in \mathcal{C}} \psi(b_{rs})$$

6. Le speckle simulé sur la mire n'est pas corrélé spatialement.

Comme  $\phi(x) = \frac{x}{(1+x)}$  a pour dérivée  $\frac{1}{(1+x)^2}$ , le processus bord  $b_{rs}$  est donné par :

$$b_{rs} = \frac{1}{(1 + \mathcal{H}(f_r - f_s))^2}$$

Quant à l'expression de récurrence intervenant pour le calcul de  $f^{(n+1)}$ , comme :

$$\begin{aligned} \frac{\partial U}{\partial f_s} &= 2(f_s - p_s) + 2\lambda \sum_{r \in \mathcal{N}_s} b_{rs}(f_s - f_r) \\ \text{et } \frac{\partial^2 U}{\partial f_s^2} &= 2(1 + \lambda \sum_{r \in \mathcal{N}_s} b_{rs}) \end{aligned}$$

on obtient :

$$f_s^{(n+1)} - f_s^{(n)} = -\frac{1}{1 + \lambda \sum_{r \in \mathcal{N}_s} b_{rs}} \left( f_s^{(n)} - p_s + \lambda \sum_{r \in \mathcal{N}_s} b_{rs}(f_s^{(n)} - f_r^{(n)}) \right) \quad (5.3)$$

Ce schéma a été appliqué dans deux cas : en prenant la bonne valeur de  $b_{rs}$ , et en utilisant le processus bord modifié de la section 5.3.2.

#### a. Utilisation de $b_{rs}$

La forme du processus bord est donnée par :

$$b_{rs} = \phi'(\mathcal{H}(\frac{f_s - f_r}{\delta})) = \frac{1}{\left(1 + \left(\frac{f_s - f_r}{\delta}\right)^2\right)^2}$$

Dans ce cas, les résultats obtenus ne sont pas très satisfaisants (fig.5.4). Un comportement différent dans les régions sombres et brillantes est observé : les régions sombres sont fortement régularisées alors que les régions brillantes montrent plus de variations. Notons également que ces effets, bien que présents en utilisant une estimation ponctuelle  $b_{rs}$  ou moyennée  $\overline{b_{rs}}$ , sont réduits dans le cas de  $\overline{b_{rs}}$ . De plus, le résultat contient de nombreux points isolés dans le cas de l'estimateur ponctuel.

#### b. Utilisation de $b_{rs}^*$

La forme du processus bord est donnée par :

$$b_{rs}^* = \phi'(\mathcal{H}(\frac{d_{rs}}{\delta^*})) = \frac{1}{\left(1 + \left(\frac{d_{rs}}{\delta^*}\right)^2\right)^2}$$

Puisque le gradient est remplacé par un détecteur de contours adapté à la statistique des images radar, les effets précédents ont disparu (fig.5.5). Les images restaurées sont satisfaisantes avec une bonne préservation des contours et un fort filtrage des zones homogènes.

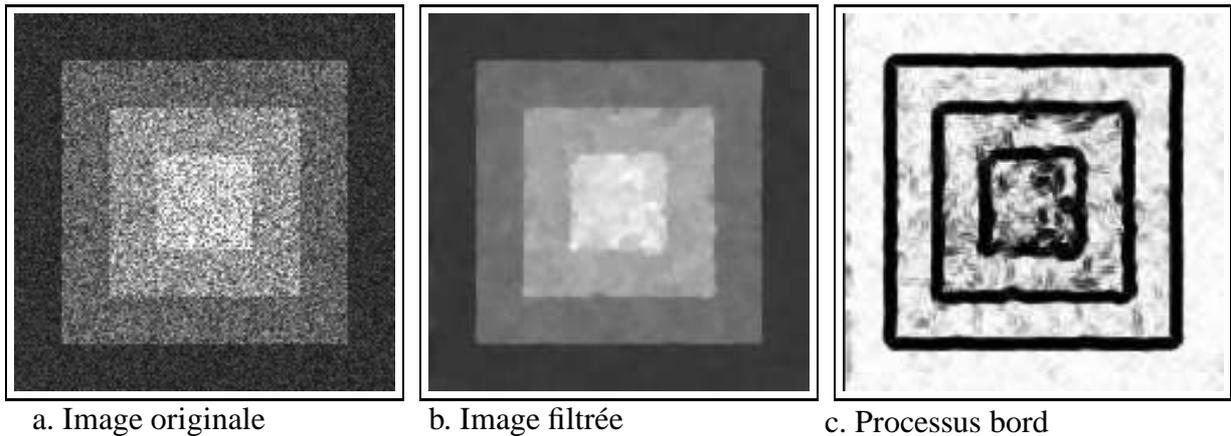


FIG. 5.4 – Régularisation avec une loi gaussienne, une fonction  $\mathcal{H}$  quadratique et  $\overline{b_{rs}}$  sur la mire synthétique

Notons également que là encore les zones homogènes sont filtrées bien plus énergiquement lors de l'estimation moyennée  $\overline{b_{rs}^*}$  que lors d'une estimation ponctuelle.

Ces résultats satisfaisants semblent à première vue en contradiction avec la présence de speckle puisque les images radar ne suivent pas une distribution gaussienne. Une explication de ce résultat réside dans le comportement du processus de filtrage. En effet, l'expression de récurrence est :

$$f_s^{(n+1)} = \frac{1}{1 + \lambda \sum_{r \in \mathcal{N}_s} b_{rs}} \left( p_s + \sum_{r \in \mathcal{N}_s} b_{rs} f_r^{(n)} \right)$$

En réalité, la nouvelle valeur au site  $s$  est une moyenne pondérée entre l'observation et les valeurs régularisées des voisins, les pondérations mesurant la présence ou l'absence d'un contour. Ainsi, après quelques itérations, la densité de probabilité de  $f$  devient presque gaussienne.

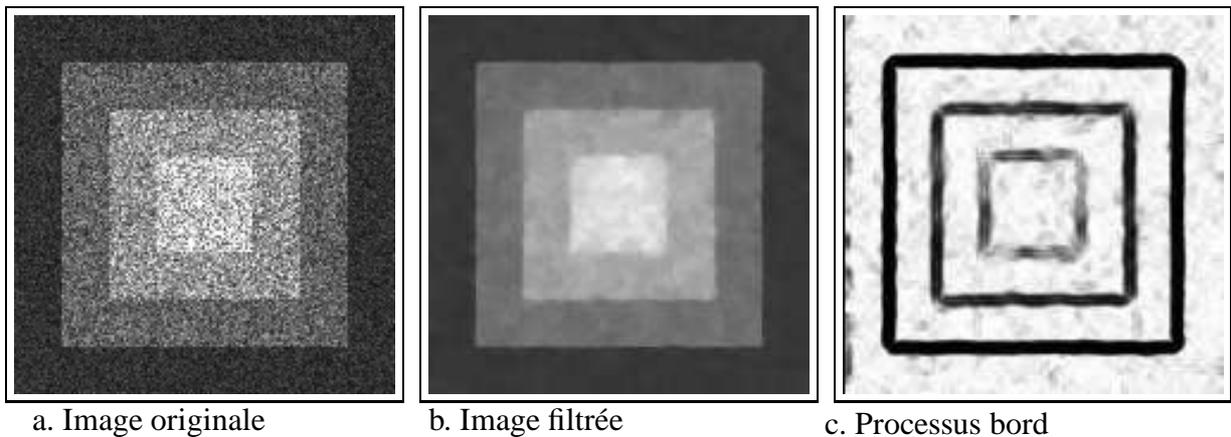


FIG. 5.5 – Régularisation avec une loi gaussienne, une fonction  $\mathcal{H}$  quadratique et  $\overline{b_{rs}^*}$  sur la mire synthétique

### 5.3.5 Distribution gamma généralisée et fonction $\mathcal{H}$ quadratique

Pour améliorer la restauration, une loi gamma généralisée a été utilisée pour le terme d'attache aux données (cette loi étant, comme on l'a vu au chapitre 1, bien plus adaptée qu'une loi gaussienne pour des images radar) :

$$Pr(p_s | f_s) = k \frac{p_s^{2L-1}}{f_s^{2L}} \exp\left(-\frac{Lp_s^2}{f_s^2}\right)$$

où  $k$  est une constante (équation 1.4<sup>7</sup>). Finalement, on obtient l'énergie  $U_1(f)$  :

$$U_1(f) = L \left( \sum_{s \in S} 2 \log f_s + \frac{p_s^2}{f_s^2} \right)$$

En calculant les différentes dérivées, on obtient l'expression suivante :

$$f_s^{(n+1)} - f_s^{(n)} = -\frac{1}{\frac{2L}{f_s^{(n)4}}(3p_s^2 - f_s^{(n)2}) + 2\lambda \sum_{r \in \mathcal{N}_s} b_{rs}} \left( \frac{2L}{f_s^{(n)3}}(f_s^{(n)2} - p_s^2) + 2\lambda \sum_{r \in \mathcal{N}_s} b_{rs}(f_s^{(n)} - f_r^{(n)}) \right)$$

Plusieurs problèmes se posent pour l'utilisation de cette expression. Tout d'abord, il faut que  $\omega = \frac{1}{\frac{\partial^2 U}{\partial f_s^2}}$  soit négatif pour la convergence de la méthode de Newton-Raphson. Cela

impose :

$$\frac{2L}{f_s^{(n)4}}(3p_s^2 - f_s^{(n)2}) + 2\lambda \sum_{r \in \mathcal{N}_s} b_{rs} > 0$$

Comme dans tous les cas traités  $3p_s^2 > f_s^2$ , nous n'avons pas observé en pratique de problèmes de convergence et nous laisserons donc de côté cet aspect. Là encore, nous avons testé les deux processus bords  $b_{rs}$  et  $b_{rs}^*$ .

#### a. Utilisation de $b_{rs}$

Le phénomène précédent est maintenant inversé (filtrage plus important dans les zones claires), ce qui n'est bien sûr toujours pas satisfaisant (fig.5.6). Dans le cas d'une estimation ponctuelle du processus bord, il y a de nombreux points isolés dans le résultat, ce qui n'est plus le cas avec l'estimation moyennée.

#### b. Utilisation de $b_{rs}^*$

Le même phénomène d'un filtrage ayant un comportement complètement différent sur les zones claires et sombres est observé et la remarque précédente pour les points isolés est également vérifiée (voire accentuée, fig.5.7). Bien sûr, l'objectif de la régularisation est de filtrer de la même façon des zones physiquement homogènes et de donner en résultat des

---

7. Nous cherchons ici à restaurer non pas l'intensité moyenne  $2\sigma^2$  (éq.1.4) mais sa racine carrée pour rester dans la même dynamique que l'image originale.

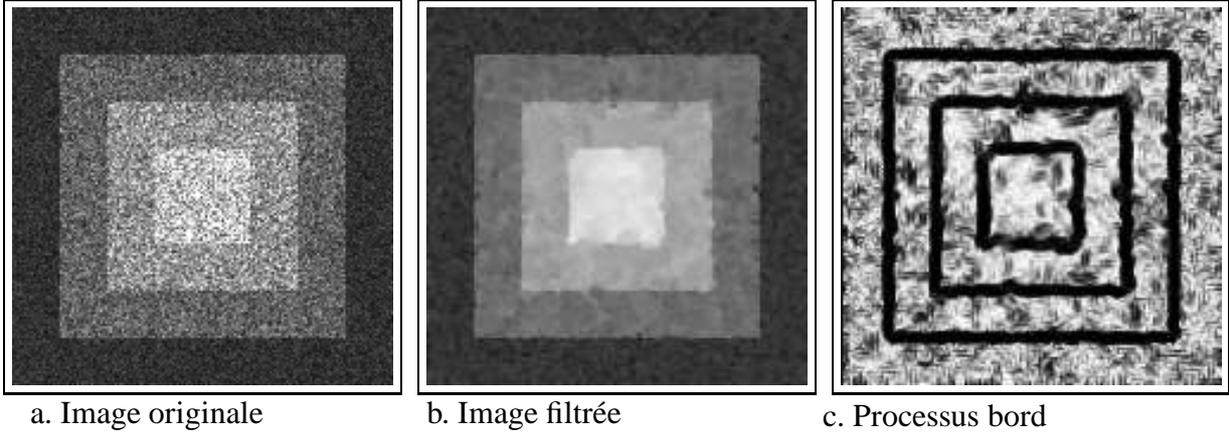


FIG. 5.6 – Régularisation avec une loi gamma généralisée, une fonction  $\mathcal{H}$  quadratique et  $\overline{b_{rs}}$  sur une image synthétique

zones les plus homogènes possibles. Ce n'est pas le cas lorsqu'on utilise une distribution Gamma généralisée et une fonction  $\mathcal{H}$  quadratique, quel que soit le processus bord. Considérons deux cas extrêmes :

- quand  $f_s \rightarrow \infty$  (précisément pour  $f_s^2 \gg \frac{KL}{\lambda} \max(1, \frac{|f_s - p_s|}{|f_s - f_r|})$ ,  $1 \leq K \leq 10$ ):

$$f_s^{(n+1)} \approx \frac{\sum_{r \in \mathcal{N}_s} b_{rs} f_r^{(n)}}{\sum_{r \in \mathcal{N}_s} b_{rs}}$$

ainsi, seul le terme de régularisation compte sur les régions claires, ce qui conduit à des régions très lissées ;

- quand  $f_s \rightarrow 0$  (précisément pour  $f_s^2 \ll \frac{KL}{\lambda} \min(1, \frac{|f_s - p_s|}{|f_s - f_r|})$ ,  $1 \leq K \leq 10$ ):

$$f_s^{(n+1)} \approx f_s^{(n)} + f_s^{(n)} \frac{f_s^{(n)2} - p_s^2}{f_s^{(n)2} - 3p_s^2}$$

donc le terme de régularisation n'apparaît plus sur les régions sombres.

Ces deux comportements sont bien ceux observés en pratique. Dans les deux cas (bon  $b_{rs}$  ou  $b_{rs}$  modifié en  $b_{rs}^*$ ), les zones claires sont trop lissées, tandis que les sombres ne le sont pas du tout. Notons que cet effet est encore accentué par l'utilisation de  $b_{rs}^*$ .

### 5.3.6 Distribution gamma généralisée et fonction $\mathcal{H}$ adaptée

Pour que la régularisation ait lieu de la même façon dans les régions sombres et brillantes, il faut que le terme d'attache aux données et le terme contextuel aient la même pondération quelle que soit la radiométrie d'une région. En particulier, si nous remplaçons  $p_s$  par  $\alpha p_s$

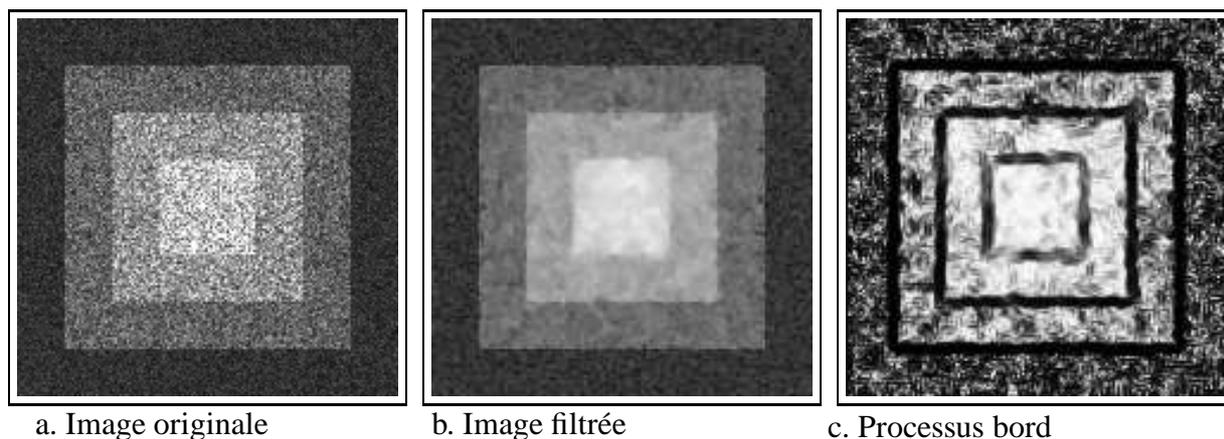


FIG. 5.7 – Régularisation avec une loi gamma généralisée, une fonction  $\mathcal{H}$  quadratique et  $\bar{b}_{rs}^*$  sur la mire synthétique

et  $f_s^{(n)}$  par  $\alpha f_s^{(n)}$  pour tout  $s$ , nous souhaitons obtenir  $\alpha f_s^{(n+1)}$  à la place de  $f_s^{(n+1)}$ . Or nous avons :

$$\frac{\partial U_1}{\partial f_s} = \frac{2L}{f_s^{(n)3}} (f_s^{(n)2} - p_s^2)$$

Cette expression est homogène de degré  $-1$  par rapport à  $f_s$  et  $p_s$  (par cela nous exprimons que  $\frac{\partial U_1}{\partial f_s}(\alpha p | \alpha f) = \frac{1}{\alpha} \frac{\partial U_1}{\partial f_s}(p | f) \forall \alpha$ ). Par conséquent, pour que le terme d'attache aux données et le terme contextuel aient la même importance, il nous faut choisir une fonction  $\mathcal{H}$  dont la dérivée soit aussi de degré  $-1$  par rapport à  $f_r$  et  $f_s$ . Cela est vérifié pour une fonction  $\mathcal{H}$  homogène de degré  $0$  par rapport à  $f_r$  et  $f_s$ . Par ailleurs, ce choix impose aux dérivées secondes d'être toutes les deux de degré  $-2$ . Finalement, si nous remplaçons  $p_s$  par  $\alpha p_s$ ,  $f_s$  par  $\alpha f_s$ , alors  $f_s^{(n+1)}$  est estimé par :

$$\alpha f_s^{(n)} + \frac{1}{\frac{1}{\alpha^2} \frac{\partial^2 U}{\partial f_s^2}} \left( \frac{1}{\alpha} \frac{\partial U}{\partial f_s} \right)$$

donc remplacé par  $\alpha f_s^{(n+1)}$ , ce qui est bien le résultat souhaité.

Nous proposons donc de choisir une fonction  $\mathcal{H}$  de  $f_r$  et  $f_s$  répondant au critère précédent. Pour ce faire, nous introduisons d'abord une nouvelle variable  $R_{rs}$  définie pour deux sites  $r$  et  $s$  par  $R_{rs} = \frac{f_r}{f_s}$ , et nous définissons  $\mathcal{H}(R_{rs}) = R_{rs} + \frac{1}{R_{rs}} - 2$ . Cette quantité est toujours positive<sup>8</sup>, minimale lorsque  $f_r = f_s$ , symétrique en  $(f_r, f_s)$ , homogène de degré  $0$  par rapport à  $f_r$  et  $f_s$  et de plus convexe par rapport à chacune de ces variables. Par ailleurs, comme les valeurs en  $R_{rs}$  et  $\frac{1}{R_{rs}}$  sont les mêmes, nous considérons seulement l'intervalle de définition  $[1, +\infty[$ . Pour normaliser l'expression, on utilise plutôt :

$$\mathcal{H}(x) = \frac{1}{\delta'} \left( x + \frac{1}{x} - 2 \right) \text{ avec } \delta' = \delta + \frac{1}{\delta} - 2$$

8.  $\mathcal{H}$  est une fonction décroissante sur  $[0, 1]$ , croissante sur  $[1, +\infty[$  et passe par un minimum en  $1$  où elle prend la valeur  $0$ .

où, comme précédemment,  $\delta$  est une constante de normalisation. L'énergie totale s'écrit, d'après le théorème :

$$U(f) = L \left( \sum_{s \in S} 2 \log f_s + \frac{p_s^2}{f_s^2} \right) + \lambda \sum_{(r,s) \in \mathcal{C}} b_{rs} \left( \frac{f_r}{f_s} + \frac{f_s}{f_r} - 2 \right) + \mu \sum_{(r,s) \in \mathcal{C}} \psi(b_{rs})$$

Le processus bord quant à lui est donné par :

$$b_{rs} = \frac{1}{\left( 1 + \frac{1}{\delta'} \left( R_{rs} + \frac{1}{R_{rs}} - 2 \right) \right)^2} \quad (5.4)$$

Là encore, nous avons testé une estimation ponctuelle avec  $R_{rs}$  et une estimation "moyennée", où  $R_{rs}$  est remplacé par le rapport des moyennes locales. En résumé, nous proposons de remplacer  $\mathcal{H}(f_r - f_s) = (f_r - f_s)^2$  par  $\mathcal{H}\left(\frac{f_r}{f_s}\right) = \frac{f_r}{f_s} + \frac{f_s}{f_r} - 2$  dans le cas des images radar. Ce résultat est en effet cohérent, car  $\frac{f_r}{f_s} + \frac{f_s}{f_r} - 2$  correspond à une détection de contour, similaire à  $1 - \min\left(\frac{f_r}{f_s}, \frac{f_s}{f_r}\right)$ , mais définie sur  $[1, +\infty[$  et bien plus facile à dériver.

Les résultats obtenus sont satisfaisants : les effets de la régularisation sont constants sur toute l'image et il n'y a pas de points isolés avec  $b_{rs}$  comme avec  $b_{rs}^*$ . Néanmoins, l'estimation avec le moyennage donne les meilleurs résultats avec un filtrage plus énergique sur les zones homogènes (rappelons que dans ce cas nous n'avons pas de preuve de convergence, contrairement au cas de l'estimation ponctuelle).

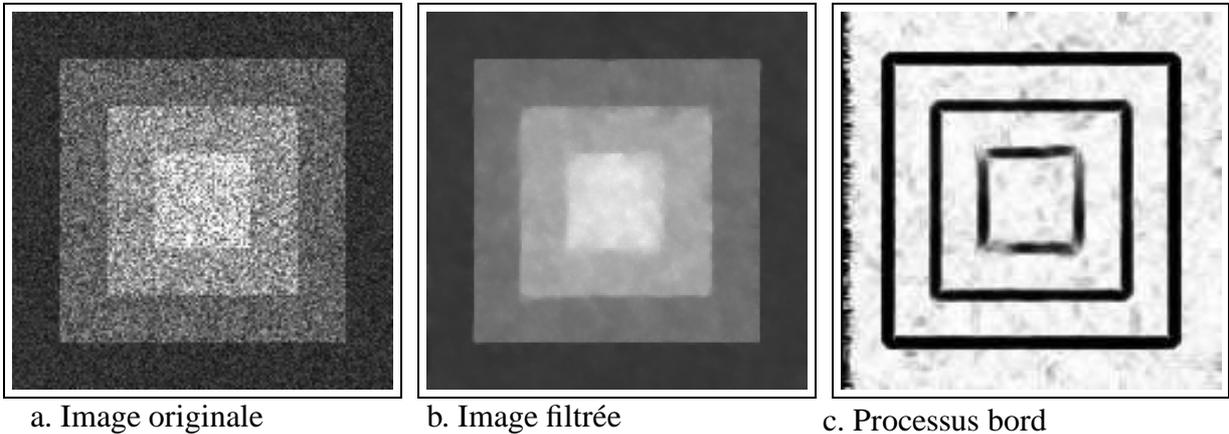
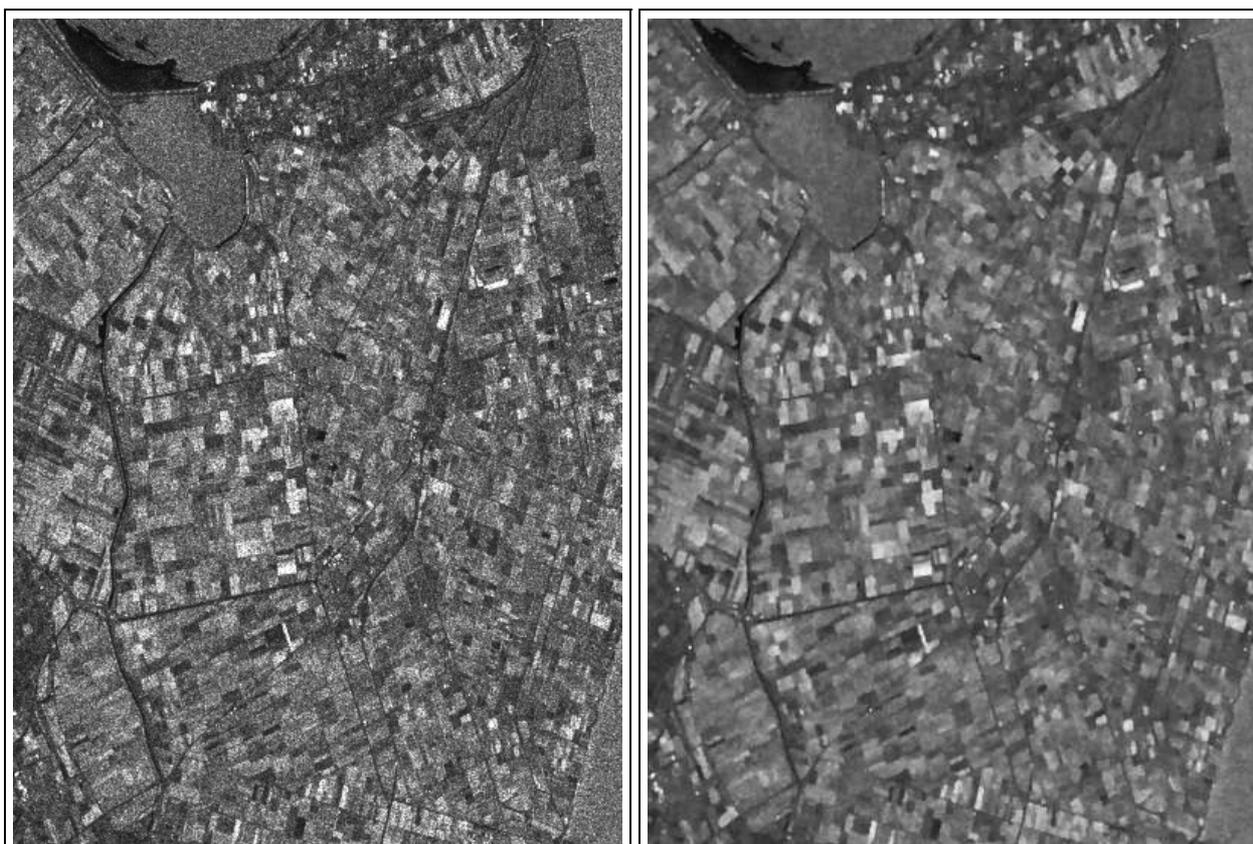


FIG. 5.8 – Régularisation avec une loi gamma généralisée, la fonction  $\mathcal{H}(x) = x + \frac{1}{x} - 2$  et le  $\overline{b_{rs}}$  correspondant sur la mire synthétique

### 5.3.7 Comparaisons entre quelques filtres

Commençons d'abord par quelques remarques d'ordre général. Dans tous les cas de meilleurs résultats ont été obtenus en utilisant des estimateurs par moyennage des processus

bords ; ou parce que le filtrage était plus énergique, ou parce que les points isolés étaient supprimés. Dans tous les cas, mis à part §5.3.4a et §5.3.6, des comportements différents suivant la radiométrie des régions ont été observés dans un sens ou dans l'autre, à cause de la nature multiplicative du bruit. Le meilleur résultat a été obtenu en introduisant une nouvelle fonction de régularisation définie à partir du rapport (§5.3.6). Un résultat sur une image réelle avec cette méthode est donnée figure 5.9.



a. Image originale (cf. annexe A.2)

b. Image filtrée

FIG. 5.9 – Régularisation avec une loi gamma généralisée et la fonction  $\mathcal{H}(x) = x + \frac{1}{x} - 2$  sur une image réelle (région du Wieringermeer, ERS-1 ©ESA)

Pour comparer les performances des différents filtres, nous avons utilisé le nombre de vues équivalents [Lope-93b], calculé sur chacune des zones homogènes de la cible. Ce critère est souvent utilisé pour évaluer l'effet du filtrage (plus la valeur du nombre de vues équivalent étant élevée, meilleure étant le filtre). Le tableau 5.2 donne les résultats obtenus.

Les profils de ligne pour différents filtres sont également indiqués (cf. fig.5.10).

Remarquons que ces critères sont à manipuler avec beaucoup de précaution et qu'ils ne reflètent pas forcément fidèlement les jugements des observateurs humains<sup>9</sup>. En particulier, le filtre de Wu et Maître a parfois été jugé plus satisfaisant. D'autres critères sont d'ailleurs présentés dans [Saad-96] [EIAs-96].

9. On peut d'ailleurs se demander si le nombre de vues équivalent, bien adapté aux images radar, est encore approprié pour évaluer les images filtrées puisque celles-ci ne suivent plus les mêmes statistiques.

méthode	nombre de vues équivalent				
	région 1	région 2	région 3	région 4	moyenne
mire	3.3	3.4	3.3	3.3	3.3
§5.3.4	23.7	18.3	17.8	16.4	19
§5.3.4	14.5	17.8	18.7	19.7	17.7
§5.3.5	6.7	12.4	16.8	20.4	14
§5.3.5	4.7	9.3	15.3	19.4	12.2
§5.3.6	29.4	25.	19.	18.	22.
filtre de Kuan	10.7	9.8	13.7	15.5	10.1
filtre de Wu et Maître	11.3	10.6	11.4	12.9	11.5

TAB. 5.2 – Nombre de vues équivalent pour les différents tests et sur chaque région (numérotées de 1 à 4 en allant de l'extérieur au centre de l'image).

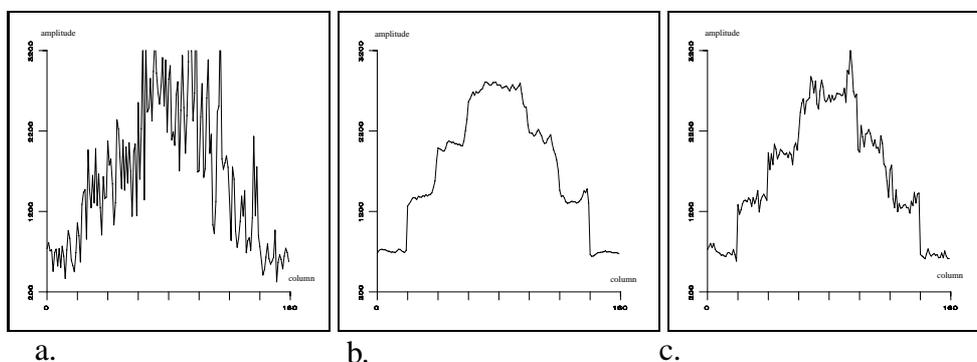


FIG. 5.10 – Profil de la ligne du milieu de la mire a) image synthétique originale, b) avec la méthode du 5.3.6, c) pour l'image filtrée avec le filtre de Wu et Maître.

### 5.3.8 Perspectives

Ce travail représente une première étude des performances des méthodes de régularisation avec prise en compte des discontinuités dans le cas du filtrage des images radar [Tupi-97]. Notre contribution au problème s'est concrétisée par la proposition de nouvelles fonctions d'énergie et par l'étude systématique de plusieurs schémas qui étaient envisageables. En particulier, nous avons été particulièrement attentifs au comportement de la régularisation dans les zones de radiométries différentes. Néanmoins, plusieurs aspects mériteraient d'être encore approfondis et étudiés, et ce travail est actuellement poursuivi dans le stage de DEA de Benoît Flasque [Flas-97].

Tout d'abord, on peut penser qu'une première façon de surmonter le problème du bruit multiplicatif (entraînant des comportements différents suivant la radiométrie) est de considérer l'image des logarithmes. Cette solution pose alors le problème du modèle d'observation à utiliser (voir par exemple [Hoek-91]). Ensuite, la solution obtenue sur le logarithme de l'image ne redonne pas forcément une solution "optimale" (et alors selon quel critère?) une fois repassé à l'exponentielle [Hill-91].

Ensuite, l'utilisation d'estimateurs provenant de moyennes locales pour le processus

bord nous semble liée au mauvais choix de la fonction  $\mathcal{H}$ . Une fonction réellement adaptée devrait certainement donner de bons résultats sans passer par ce moyennage qui nous fait sortir du cadre théorique (il resterait néanmoins à étudier si, alors même que la fonction n'est pas convexe à  $b$  fixé, nous convergions vers le minimum global). Nous avons testé d'autres fonctions  $\mathcal{H}$  qui n'ont pas donné de résultats plus satisfaisants : par exemple  $|\log(\frac{f_r}{f_s})|^\alpha$ , où  $\alpha$  est un exposant à déterminer (ce qui rappelle un gradient sur le logarithme de l'image puisque  $\log(\frac{f_r}{f_s}) = \log f_r - \log f_s$ ). Mais si nous nous limitons à des estimations ponctuelles, le résultat obtenu présente une "texture" sur les zones homogènes.

Enfin, l'intérêt final du filtrage devrait être de restituer les changements de radiométrie et plus précisément de texture à l'intérieur des surfaces stationnaires. Par conséquent, le modèle devrait à plus long terme être adapté pour pouvoir tenir compte de ce paramètre et ne pas se limiter au "cartoon" modèle.

Notons également que les difficultés liées à la convergence de l'algorithme par des méthodes déterministes pourraient être levées en se plaçant dans un cadre stochastique et en utilisant par exemple un recuit simulé. Cette approche est actuellement celle adoptée dans le stage de Benoît Flasque [Flas-97] et permettra de vérifier les résultats obtenus avec des méthodes déterministes.

Remarquons que d'autres travaux sont actuellement en cours sur des approches similaires [Math-97], l'objectif final des auteurs étant le filtrage à partir des données radar brutes.

## 5.4 Conclusion

Si l'objectif de filtrer de façon idéale les images radar reste très séduisant, il ne faut cependant jamais perdre de vue l'utilisation finale qui sera faite des images. Si le but de l'utilisateur est de faire une détection automatique de cibles, de contours ou de lignes, il peut être plus performant d'utiliser directement des détecteurs de cibles, de contours ou de lignes adaptés, plutôt que de les intégrer dans un processus de filtrage, puis d'effectuer des traitements sur l'image filtrée. C'est l'option qui a été choisie au cours de cette thèse. Si le but de l'utilisateur est d'interpréter visuellement plus facilement l'image, alors les filtres existant à l'heure actuelle sont encore très insuffisants pour répondre à cette demande. Il est presque toujours aussi facile (si ce n'est plus) d'interpréter l'image radar brute que sa version filtrée<sup>10</sup>. Les seuls filtres véritablement efficaces sont les filtres multi-temporels qui exigent un accroissement considérable de la quantité d'information apportée. Malgré ce défaut coûteux puisqu'il faut disposer de plusieurs prises de la même scène, il est prévisible que leur utilisation ira croissante à l'avenir, lorsque des jeux de données importants seront disponibles pour toutes les zones imagées.

---

10. Il s'agit d'un avis personnel s'appuyant sur les différents filtres que nous avons pu rencontrer au cours de cette thèse.

## Chapitre 6

# Segmentation des images radar

*Ce chapitre recense brièvement quelques méthodes de segmentation qui ont été proposées en imagerie radar, avant de décrire plus en détail la méthode markovienne que nous avons mise en place. Des aspects pratiques sont abordés et les résultats de cette technique appliquée à différentes échelles sont présentés. Une amélioration consistant à introduire un champ externe directionnel permettant de mieux préserver les objets linéaires est également proposée. Finalement, une application visant à la détection des zones de parcelle dense et utilisant les régions définies par cette segmentation est décrite.*

### 6.1 Quelques méthodes

Il est parfois très utile de segmenter l'image afin de travailler sur des régions. Cette étape peut, par exemple, précéder une classification symbolique ou une interprétation. Une façon de procéder est de définir des attributs sur les objets obtenus et d'appliquer des techniques de classification ; une application dans un cadre markovien est décrite à la fin de ce chapitre et au chapitre 8. Par ailleurs, la segmentation est une opération duale de la détection de contours, avec laquelle il est parfois intéressant de la combiner.

Les méthodes proposées sont nombreuses et souvent dédiées à un certain type de données (complexes, mono-vue, polarimétriques, multi-fréquentielles, etc...).

Nous pouvons tout d'abord distinguer la famille des méthodes bayésiennes. Parmi celles-ci, on trouve des approches globales et markoviennes : sur des images en amplitude mono- et multi-vues [Derin-87] [Kell-88] [Marz-96], sur des images complexes [Deri-90] [Rign-91a], et sur des images polarimétriques [Rign-91b] [Smit-97] [LeHe-96]. Des méthodes contextuelles locales non markoviennes ont également été proposées [Quel-91] [Quel-93] [Marz-96]. La thèse de S. Le Hégarat-Masclé [LeHe-96] présente et compare plusieurs méthodes de segmentation non supervisée sur des images polarimétriques, aussi bien ponctuelles (bayésiennes EM, SEM, ICE, ou k-moyennes flou) que globales (MAP, MPM, ICM).

Cependant, bien d'autres techniques ne s'inscrivant pas dans un cadre mathématique bayésien ont été développées. Citons quelques exemples :

- White couple une détection de contours puis de régions en utilisant une collection de disques de différentes tailles [Whit-91] ;

- Delvest *et al.* réalisent une croissance de régions contrôlée par la minimisation de l'erreur quadratique moyenne [Delv-91] ;
- Cook et M<sup>c</sup> Connell utilisent une méthode de fusion de régions basée sur un coût défini à partir du test de Student, en initialisant le processus par une sur-segmentation [Cook-94] ;
- Oliver *et al.* [Oliv-95] et Lombardo *et al.* [Lomb-94] testent le rapport des maxima de vraisemblance (sous l'hypothèse d'une loi gamma ou en approximant une loi  $K$ ) pour guider un schéma de fusion de régions ;
- Baraldi et Parmiggiani appliquent des filtres de Gabor à différentes résolutions [Bara-96] ;
- des approches par réseau de neurones ont également été développées [Whit-91] [Main-94] ;
- Falco *et al.* s'appuient sur l'aspect fractal pour segmenter l'image radar [Falc-96] ;
- des méthodes enchaînant une détection de contours, un algorithme de partage des eaux (watershed) pour obtenir une sursegmentation, et une étape finale de fusion des régions ont aussi été proposées [Fjor-95] [Fjor-97] [Ogor-96] ; Fjortoft *et al.* utilisent un nouveau détecteur de contours adapté aux images radar (ROEWA, Ratio of Exponentially Weighted Averages) et un test fondé sur le rapport de vraisemblance pour la fusion des régions de la sursegmentation [Fjor-98] ; les résultats obtenus avec cette méthode sur les images de parcellaire sont très convaincants.

Il est difficile de comparer ces différentes méthodes. En effet, les résultats présentés, difficilement évaluables sur les articles, sont rarement comparatifs ou la comparaison est limitée [Cave-94] [Cave-94b]. De plus, les performances d'une technique peuvent dépendre de la résolution à laquelle elle est appliquée, et des applications de l'utilisateur final (détection des limites de champs ou des bâtiments par exemple). Par ailleurs, certaines des méthodes citées sont non-supervisées, d'autres le sont ou en partie puisque, sans parler des apprentissages éventuels, certains paramètres peuvent être laissés au choix de l'utilisateur. D'une façon générale, cette revue, qui est loin d'être exhaustive, montre la diversité des méthodes de segmentation existantes (diversité qu'on retrouve d'ailleurs dans le cas des images optiques).

De plus, la limite entre méthodes de segmentation et de classification est parfois faible. Les résultats de la segmentation peuvent servir de base à une méthode de classification, comme c'est le cas dans [Sery-97], où les régions de la segmentation donnée par la méthode de Fjortoft *et al.* [Fjor-95] [Fjor-97] sont classées. Le résultat de la segmentation peut aussi être directement évalué dans un objectif de classification [LeHe-96]. Néanmoins, les méthodes de segmentation ont plutôt pour but de découper l'image en régions radiométriquement homogènes qui serviront de support à des traitements ultérieurs, alors que les méthodes de classification<sup>1</sup> attribuent à chaque pixel une classe thématique, et sont souvent supervisées [Pier-94] [Dobs-96] et ponctuelles [Nezr-96] [Chen-96] [Clou-97]. Des travaux portent également sur la classification des différents états de végétation (par exemple différents stades de la croissance du riz) à partir d'images multi-temporelles [Ribb-96] [LeTo-97].

Dans notre cas, l'objectif de la segmentation est de délimiter des régions ou objets sur lesquels des processus d'interprétation seront appliqués (un exemple pour la détection des zones de parcellaire dense est donné au chapitre suivant). Notre but n'est pas d'obtenir direc-

---

1. Les exemples de classification des images ERS-1, ou plus généralement mono-canal sont relativement rares ; en revanche, beaucoup de travaux portent sur la classification des images radar polarimétriques.

tement une classification de la scène en entités sémantiques (villes, champs, mer, relief...), mais d'accéder à un découpage de l'image, considéré comme résultat intermédiaire et qui peut être combiné de différentes manières avec les outils que nous avons proposés jusqu'à maintenant.

Nous avons opté pour une méthode bayésienne globale [Kell-88], donnant des résultats moins bruités que les méthodes contextuelles, mais au prix d'un temps de calcul plus élevé. Les résultats obtenus étant satisfaisants par rapport à l'objectif que nous nous étions fixés, nous n'avons pas testé d'autres techniques. Cela dit, si nous disposions d'une segmentation de meilleure qualité, il suffirait de remplacer celle que nous utilisons actuellement dans le processus d'interprétation (chapitre 8).

## 6.2 Une méthode markovienne

Cette méthode, qui est une méthode bayésienne globale avec une modélisation markovienne, est souvent utilisée en segmentation d'images [Gema-84] et a déjà été appliquée aux images radar [Kell-88] [Marz-96]. Nous reprenons dans la suite la démarche qui aboutit à l'expression de l'énergie et détaillons certains aspects pratiques, avant de présenter quelques résultats. Finalement, nous proposons l'introduction d'un champ externe pour préserver les structures linéaires.

### 6.2.1 Présentation

Nous cherchons au cours de la segmentation à attribuer à chaque pixel de l'image une étiquette parmi les  $M$  que nous nous donnons au départ. Ainsi, comme au chapitre 3, il s'agit de trouver la réalisation d'un champ aléatoire d'étiquettes  $E$ , connaissant des observations bruitées  $A$  qui sont les valeurs radiométriques (en amplitude). Par conséquent, les sites sur lesquels nous travaillons ici sont simplement les pixels de l'image, et la relation de voisinage est, par exemple, la 4- ou 8- connexité. Si nous adoptons un critère de Maximum A Posteriori (MAP), nous cherchons la réalisation de  $E$  maximisant  $p(E|A)$ , qui s'exprime d'après la règle de Bayes :

$$p(E|A) = \frac{p(A|E)p(E)}{p(A)}$$

Comme la probabilité  $p(A)$  ne dépend pas de l'étiquetage  $E$ , nous sommes ramenés à estimer  $p(E)$  et  $p(A|E)$ .

Etudions tout d'abord la probabilité a posteriori des données connaissant le champ d'étiquettes,  $p(A|E)$ . Nous allons ici émettre plusieurs hypothèses. Premièrement, nous supposons que les observations sont indépendantes les unes des autres, et qu'on peut écrire  $p(A|E) = \prod_{s=1}^N p(A_s|E)$ , en notant  $N$  le nombre total de sites de l'image. Cette hypothèse, comme il a déjà été précisé (cf. chapitre 1), n'est pas justifiée en raison de la corrélation des pixels. Nous reviendrons sur ce problème et sur des solutions possibles plus loin. Deuxièmement, nous allons supposer que l'observation en un site ne dépend que de l'étiquette en

ce site. Cette hypothèse, qui est plutôt réaliste, permet d'écrire  $p(A|E) = \prod_{s=1}^N p(A_s|E_s)$ . Troisièmement, nous allons supposer que le terrain est constitué de  $M$  zones parfaitement homogènes d'intensité moyenne rétrodiffusée  $\mu_k = 2\sigma_k^2 \forall k \in \{1, \dots, M\}$  et rugueuses devant la longueur d'onde. Dans ce cas, le chatoiement est totalement développé et la densité de probabilité de l'amplitude s'écrit (équation 1.4) :

$$p(A_s = a_s | E_s = e_s) = \frac{2L^L}{\mu_{e_s}^L \Gamma(L)} a_s^{(2L-1)} \exp\left(-\frac{La_s^2}{\mu_{e_s}}\right)$$

Nous nous sommes placés ici dans le cas d'une image L-vues en amplitude, ce qui est le cas des produits ERS-1 PRI. Des expressions équivalentes existent pour les autres modélisations (cf. chapitre 1).

Il nous reste maintenant à définir la probabilité a priori de l'étiquetage,  $p(E)$ . Comme pour la détection des objets linéaires, nous allons supposer  $E$  markovien, c'est à dire que :

$$\begin{aligned} \forall e \in \Omega, p(E = e) &> 0 \\ p(E_s = e_s | E_t = e_t, t \neq s) &= p(E_s = e_s | E_t = e_t, t \in \mathcal{V}_s) \end{aligned}$$

en notant  $\mathcal{V}_s$  le voisinage du site  $s$ , et  $\Omega$  l'ensemble des étiquetages possibles. Ainsi, en utilisant l'équivalence champ de Markov-champ de Gibbs donnée par le théorème de Hammersley-Clifford, on obtient :

$$\begin{aligned} p(E = e) &= \frac{e^{-U(e)}}{Z} \\ U(e) &= \sum_{c \in \mathcal{C}l} V_c(e) \end{aligned}$$

où  $\mathcal{C}l$  représente l'ensemble des cliques (cf. chapitre 3) et  $Z$  est une constante de normalisation. En choisissant un voisinage en 4- ou 8-connexité, nous limitons l'influence d'une étiquette à un voisinage restreint. Il nous reste à choisir les potentiels des cliques. Seuls les potentiels des cliques d'ordre 2 sont ici pris non nuls. Le modèle utilisé est un modèle de Potts [Gema-84], défini par :

$$\begin{aligned} V_{c=(s,t)}(e_s, e_t) &= \beta \text{ si } e_s \neq e_t \\ &= -\beta \text{ si } e_s = e_t \end{aligned}$$

En prenant  $\beta$  positif, les voisinages de pixels ayant les mêmes étiquettes sont favorisés, ce qui aboutit à une solution constituée de zones homogènes compactes, et supprime généralement les lignes et les points isolés. Des modèles plus complexes et sur des voisinages plus grands pourraient bien sûr être utilisés, permettant par exemple de conserver des structures linéaires et ponctuelles (voir §6.2.4).

Le champ des étiquettes conditionnellement aux observations est alors lui aussi markovien, puisque sa probabilité s'écrit :

$$p(E|A) = \frac{e^{-U(E|A)}}{Z'} \text{ avec } U(E|A) = L \sum_s \left( \frac{a_s^2}{\mu_{e_s}} + \ln \mu_{e_s} \right) + \sum_{c \in \mathcal{C}l} V_c(l)$$

Maximiser la probabilité d'une réalisation revient à minimiser l'énergie  $U(E|A)$ . Le premier terme de cette énergie s'interprète comme un terme d'attache aux données, et le second comme un terme contextuel qui contraint la solution à être formée de zones homogènes. La minimisation de cette énergie non convexe s'effectue par un recuit simulé selon l'algorithme de Métropolis [Gema-84].

Revenons sur l'hypothèse d'indépendance des sites nécessaire à l'expression de la probabilité a posteriori  $p(A|E)$ . Kelly et Derin [Kell-88] proposent de tenir compte de la corrélation existant en réalité, en exprimant la densité de probabilité de l'intensité non pas seulement pour un site, mais pour un vecteur de cinq sites, un site central et ses quatre plus proches voisins. Dans le cas des images 1-vue, une expression analytique peut effectivement être obtenue et il est possible, en faisant certaines approximations, d'exprimer la probabilité  $p(E_s = e_s | E^*, A)$ , où  $E^*$  est le champ d'étiquettes moins le site  $s$ . Dans le cas multi-vues avec  $L$  vues, la convolution des  $L$  lois Gamma rend impossible l'expression analytique de la densité de probabilité du vecteur des intensités. Une solution pourrait être l'utilisation de l'approximation proposée par Quelle dans le cadre d'une méthode de segmentation bayésienne locale [Quel-93]. Notre opinion personnelle (et par rapport à notre objectif d'interprétation globale de la scène) est que la prise en compte de la corrélation des pixels apporterait une amélioration minime au regard de la complexité algorithmique qu'elle entraîne. En effet, il est alors nécessaire de connaître pour chaque classe les coefficients de corrélation horizontale et verticale, et le recuit simulé demande un nombre d'opérations considérablement plus grand [Kell-88].

Notons qu'il est également possible de supposer des zones texturées avec des distributions dans le système de Pearson [Marz-96] et non simplement des lois Gamma.

## 6.2.2 Aspects pratiques

L'expression de l'énergie à minimiser fait intervenir plusieurs paramètres : les moyennes des classes  $\mu_k \forall k \in \{1, \dots, M\}$  et  $\beta^2$ . De plus, il faut fixer un nombre de classes pour segmenter l'image. Ce choix est important puisque des résultats différents seront obtenus pour des nombres de classes différents. Nous avons arbitrairement choisi de segmenter l'image en quinze classes, ce qui permet de réaliser un compromis entre un trop petit nombre de classes qui sous-segmente l'image, et un trop grand qui la sur-segmente. Ce nombre a été choisi empiriquement après des essais sur les images de notre base de données.

Puisque les classes n'ont pas de signification sémantique dans notre application<sup>3</sup> et afin d'automatiser la segmentation, nous déterminons les moyennes des classes  $\mu_k \forall k \in \{1, \dots, M\}$  en appliquant une classification par nuées dynamiques sur l'image. Cette classification sert d'initialisation au recuit simulé. Une autre solution, lorsque l'objectif est directement de classer l'image, peut consister en un apprentissage sur des zones sélectionnées manuellement. Le voisinage a été choisi 8-connexe et la valeur de  $\beta$  a été fixée empiriquement, sachant que  $\beta = 0$  ne régularise pas l'image et que  $\beta \rightarrow \infty$  tend à segmenter l'image

2. Les classes n'ont pour nous pas de contenu sémantique. Par conséquent, il est légitime de prendre le même paramètre de Potts pour toutes les classes.

3. Nous cherchons simplement à obtenir un découpage de l'image qui pourra venir alimenter d'autres processus.

en une seule région homogène. Des méthodes comme l'EM gibbsien [Chal-89] ou le ICE gibbsien [Piec-94] [Marz-96] permettent une détermination automatique de ces paramètres pour un nombre de classes fixé. L'estimation automatique du nombre de classes reste, quant à elle, un problème difficile. La solution proposée par S. Le Hégarat-Masclé dans le cadre d'une classification par k-moyennes floue [LeHe-96] pourrait être utilisée dans une étape préliminaire pour déterminer automatiquement le nombre de classes et calculer les paramètres associés, éventuellement pour des distributions prises dans le système de Pearson.

Par ailleurs, pour le recuit simulé nous avons choisi une décroissance géométrique de la température, la température initiale étant empiriquement fixée. Le recuit simulé s'arrête lorsque le nombre de modifications au cours d'un balayage de l'image est inférieur au nombre de pixels dans une ligne. Le tableau 6.1 recense les paramètres nécessaires et les valeurs utilisées en pratique.

TAB. 6.1 – Valeurs des paramètres

Température initiale	5
Facteur de décroissance géométrique	0,95
Paramètre de régularisation $\beta$	0,4
Nombre de classes	15
Nombre d'itérations pour les k-moyennes	20

Pour améliorer les contours du résultat obtenu, nous proposons d'effectuer un second recuit simulé, en considérant autant de classes que de régions segmentées. Les moyennes des classes sont calculées empiriquement sur chacune des régions, et les changements d'étiquette ne sont envisagés que pour les sites ayant un voisin de label différent. Cette seconde étape permet un meilleur positionnement des frontières entre les régions obtenues.

### 6.2.3 Résultats

La méthode telle que décrite précédemment a été appliquée sur les images de Kourou et du Flevoland. Les régions obtenues sont montrées sur les figures 6.1a et 6.2a, le niveau de gris d'une région correspondant à sa radiométrie moyenne. Les contours définis par la segmentation sont montrés figures 6.1b et 6.2b.

Le résultat de la segmentation dépend de la résolution à laquelle elle est effectuée. Si nous la dégradons par simple moyennage de groupes de pixels, la méthode précédente peut être appliquée en changeant le nombre de vues intervenant dans la probabilité a posteriori, et donc en remplaçant  $L$  dans le terme d'attache aux données qui est :

$$L \sum_s \left( \frac{a_s^2}{\mu_{e_s}} + \ln \mu_{e_s} \right)$$

Pour une dégradation à des pixels de  $25 \times 25$ m, en moyennant par blocs  $2 \times 2$ , le nombre de vues équivalent est de 6, et à  $50 \times 50$ m (blocs  $4 \times 4$ ), de 17.

Pour pouvoir comparer les résultats obtenus à des résolutions différentes, les moyennes des dix classes données par le k-moyennes à la résolution initiale sont utilisées. Les figures

6.3 et 6.4 a et b, montrent une meilleure segmentation des grandes zones de mer lorsque la résolution se dégrade, au prix d'une moins bonne détection des petites zones. Les images 6.3c et 6.4c présentent les frontières des régions qui ont été détectées à plusieurs échelles (un ET logique est appliqué entre les différentes images de contours).

## 6.2.4 Préservation des objets linéaires

Comme nous l'avons mentionné précédemment, le modèle de Potts utilisé pour la segmentation n'est pas approprié à la préservation des lignes et des réponses ponctuelles. Par exemple, le "chien-modèle" [Desc-95] a été développé pour pallier cette insuffisance. Il considère des cliques plus complexes mais qui envisagent toutes les configurations possibles (un des problèmes cruciaux est alors le réglage des différents paramètres). On peut également envisager des cliques adaptées spatialement suivant le contenu de l'image [Smit-96].

Nous proposons ici de prendre en compte la linéarité des objets correspondants à certaines classes<sup>4</sup> (les routes, les lignes de relief par exemple) en introduisant un nouveau champ externe en plus de l'image radiométrique [Tupi-96c]. Ce champ possède deux composantes :  $L$  qui mesure la présence ou l'absence de lignes, et  $D$  la direction la plus probable de cette ligne. Le champ de directions  $D$  peut prendre 8 valeurs correspondant à  $0$ ,  $\frac{\pi}{8}$ ,  $\frac{\pi}{4}$ , etc., et une valeur notée  $\emptyset$  indiquant l'absence de structure linéaire. Une observation de ces champs peut être obtenue en utilisant par exemple les détecteurs du chapitre 2. Le problème est alors ramené à la recherche de la configuration de  $L$  maximisant la probabilité  $p(E|A, L, D)$ . Sous l'hypothèse d'indépendance des champs, on a :

$$p(E|A, L, D) \propto p(A|E)p(L|E)p(D|E)p(E)$$

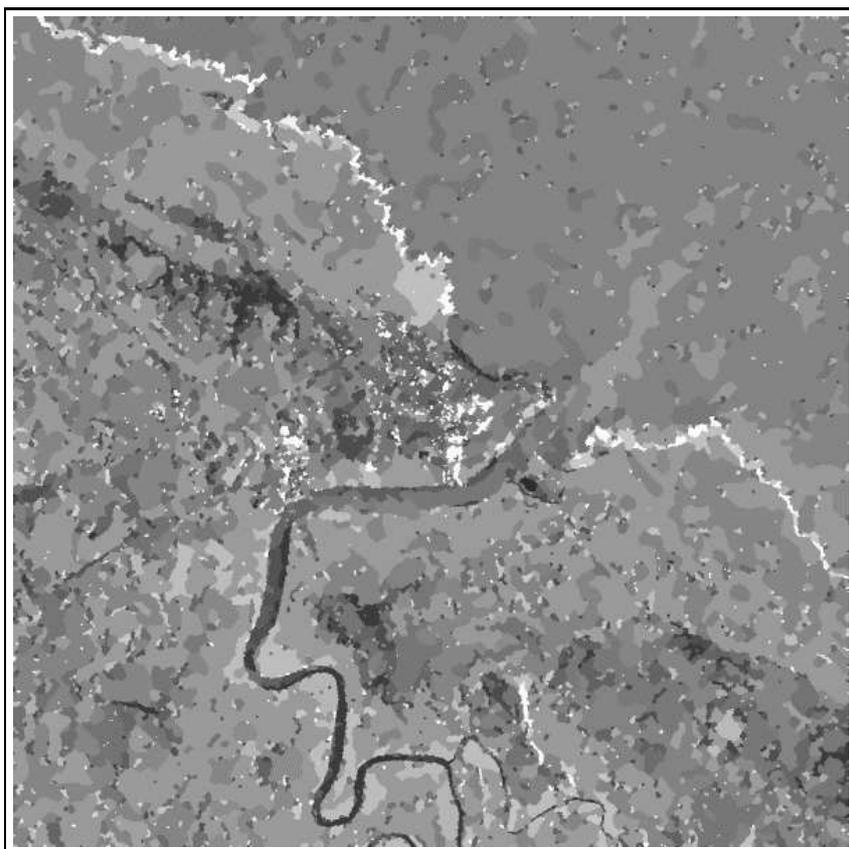
Les termes  $P(A|E)$  et  $p(L|E)$  pouvant être déduits comme précédemment, il nous reste à exprimer  $p(E)$  et  $p(D|E)$ . Nous proposons ici de conserver un modèle de Potts pour traduire l'a priori sur le champ d'étiquettes, mais d'utiliser la probabilité du champ des directions conditionnellement aux étiquettes pour préserver les structures linéaires. En effet, il serait naturel, pour un pixel ayant une étiquette correspondant à un objet linéaire, de ne pas tenir compte de tous ses 4 ou 8 plus proches voisins mais plutôt de ses seuls voisins situés dans la direction la plus probable de la structure linéaire. Nous supprimons donc le terme usuel de régularisation et le remplaçons par un terme directionnel.

Formellement, notons  $e_{\text{lin}}$  une étiquette correspondant à un objet linéaire et  $V(e_s|e_t, t \in \mathcal{V}_s)$  le potentiel défini par :

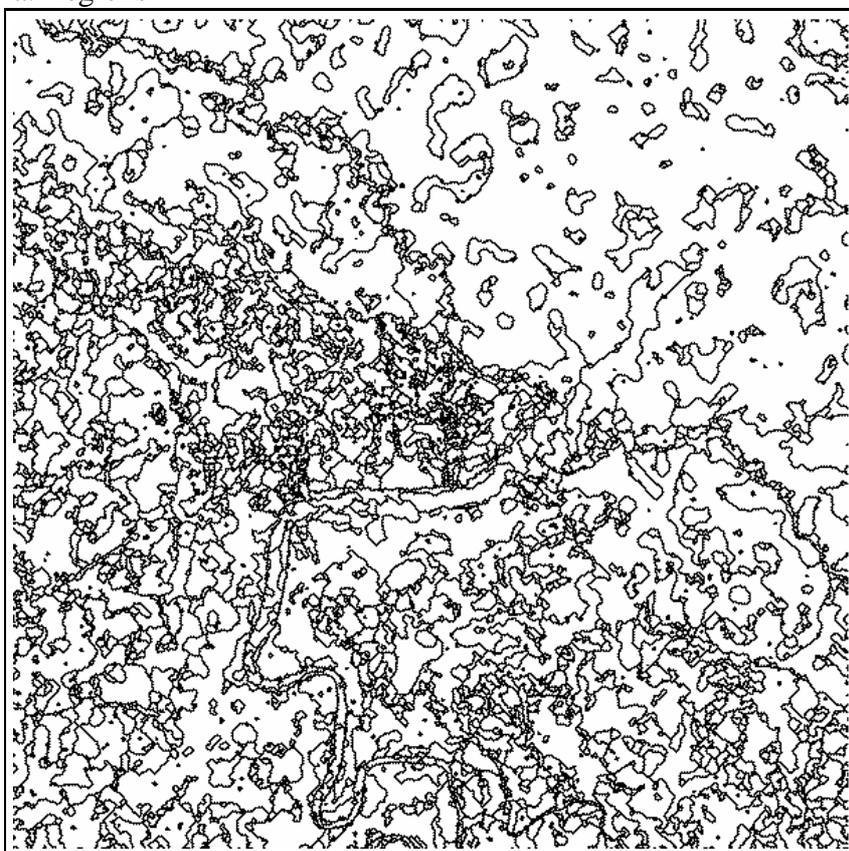
$$V(e_s|e_t, t \in \mathcal{V}_s) = \sum_{c=(s,t)/s \in c} V_c(e_s, e_t)$$

avec  $\mathcal{V}_s$  le voisinage de  $s$ .

4. Dans ce paragraphe, les classes ont un contenu sémantique puisqu'on sait par exemple si elles correspondent à des structures linéaires.

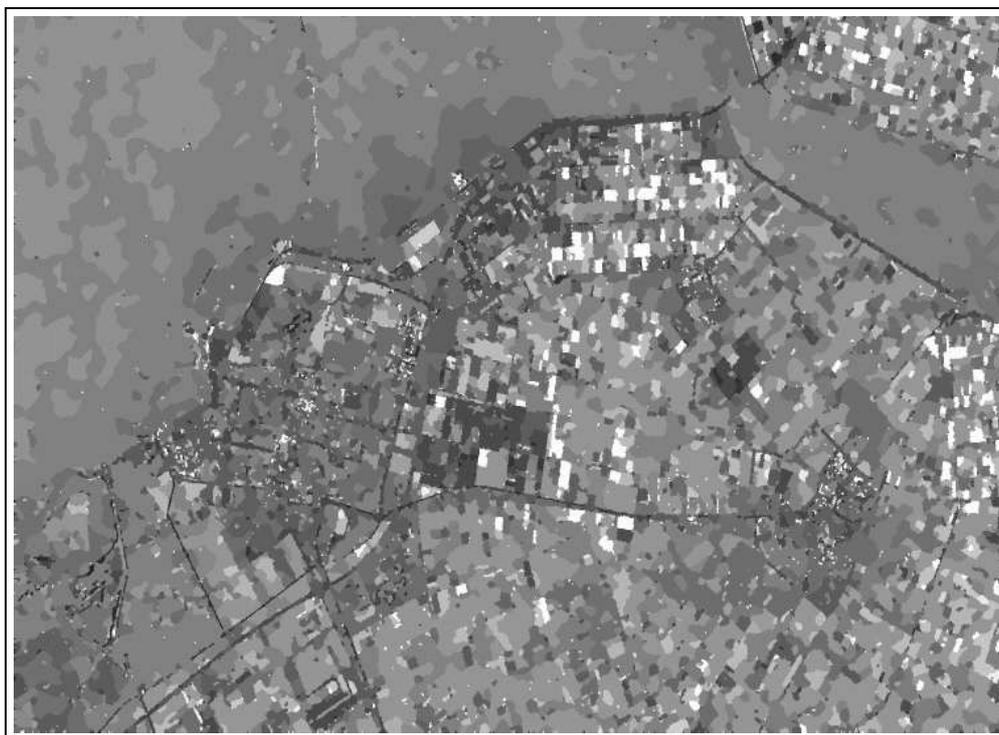


a. Régions



b. Contours

FIG. 6.1 – Résultat des deux étapes de la segmentation ( $k$ -moyennes et recuit simulé) sur l'image de Kourou à la résolution initiale (image radar originale cf. annexe §A.6)

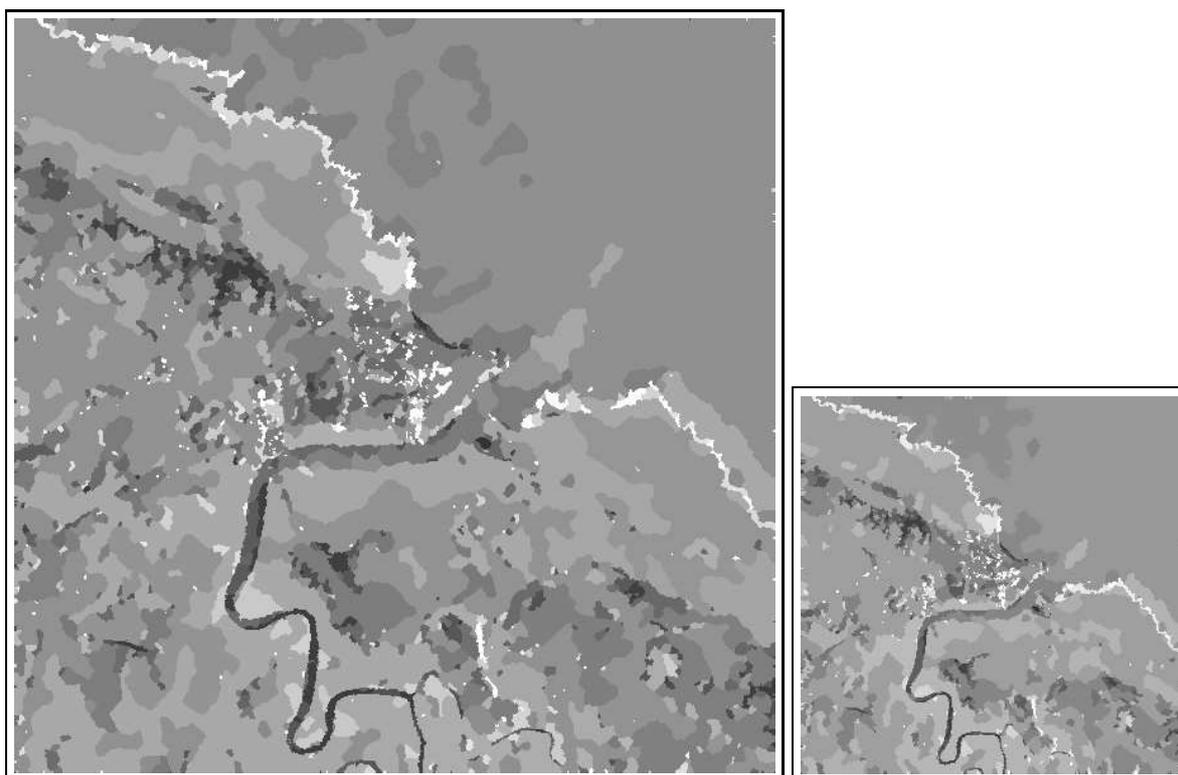
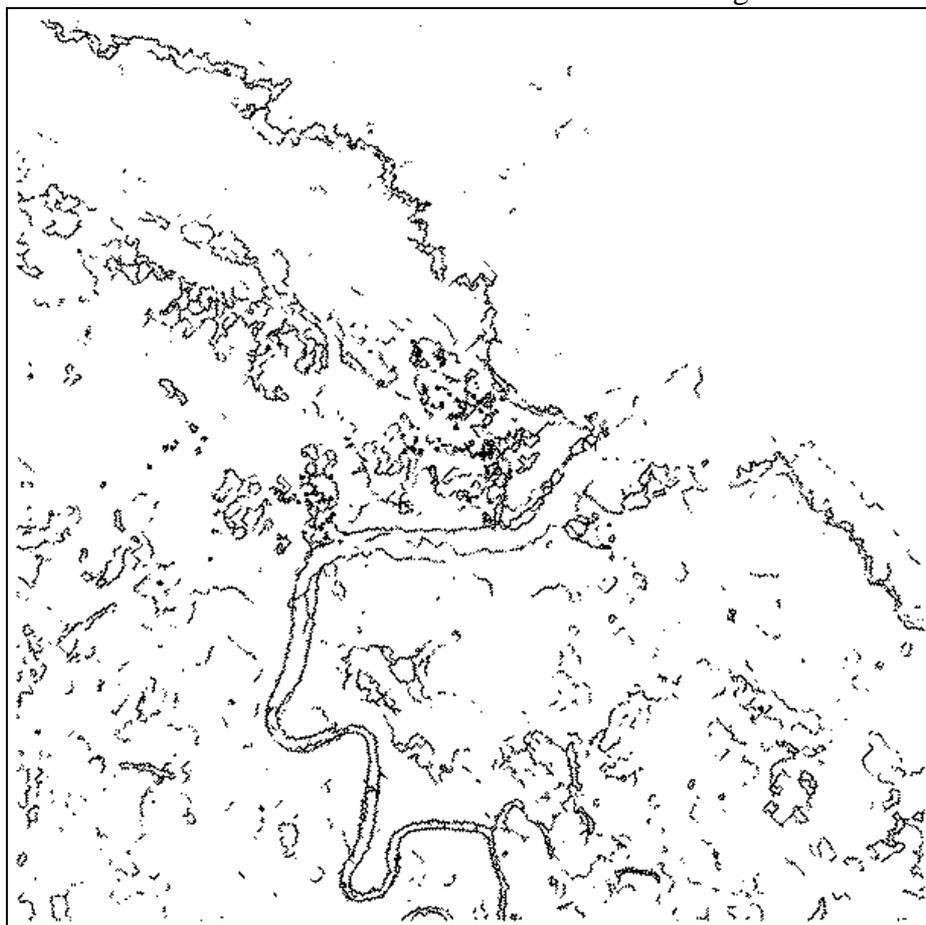


a. Régions



b. Contours

FIG. 6.2 – Résultat des deux étapes de la segmentation ( $k$ -moyennes et recuit simulé) sur l'image du Flevoland à la résolution initiale (image radar originale cf. annexe §A.2)

a. Dégradation  $2 \times 2$ b. Dégradation  $4 \times 4$ 

c. Contours détectés aux trois échelles

FIG. 6.3 – Résultat des deux étapes de la segmentation ( $k$ -moyennes et recuit simulé) sur l'image de Kourou à des résolutions dégradées et fusion des contours détectés aux trois échelles (image radar originale cf. annexe §A.6)

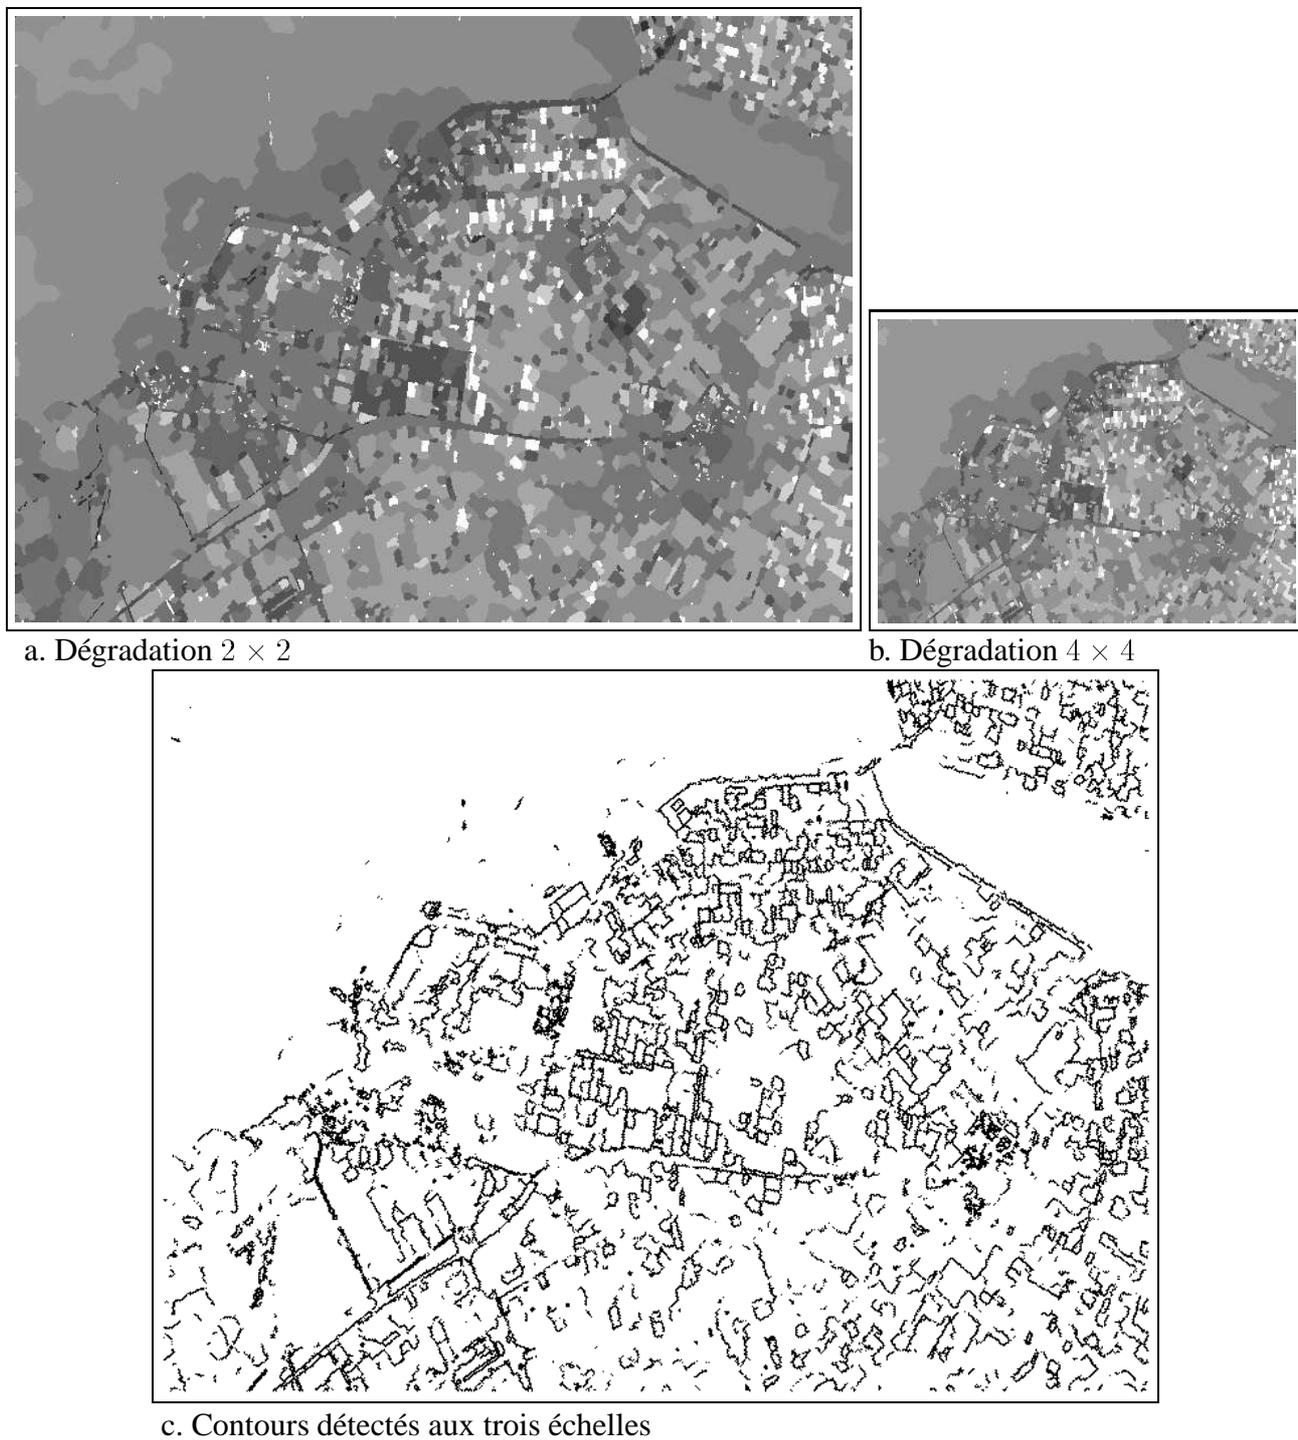


FIG. 6.4 – Résultat des deux étapes de la segmentation (*k*-moyennes et recuit simulé) sur l'image du Flevoland à des résolutions dégradées et fusion des contours détectés aux trois échelles (image radar originale cf. annexe §A.2)

Nous définissons alors l'énergie pour  $p(D|E)$  par :

$$\begin{aligned} U(d_s|e) &= U(d_s|e_s, e_t, t \in \mathcal{V}_s^*) \\ &= \delta_{e_s=e_{\text{lin}}} \delta_{d_s \neq \emptyset} \left[ -V(e_s|e_t, t \in \mathcal{V}_s) + \min \left( U_{\text{ori}}(l_s | l_{s'}, s' \in \mathcal{V}_{\text{ori}}^1), U_{\text{ori}}(l_s | l_{s'}, s' \in \mathcal{V}_{\text{ori}}^2) \right) \right] \end{aligned} \quad (6.1)$$

$$\text{avec } U_{\text{ori}}(e_s | \mathcal{V}_{\text{ori}_s}) = \frac{1}{2} \sum_{s' \in \mathcal{V}_{\text{ori}_s}} V_c(e_s, e_{s'})$$

Les voisinages utilisés pour le terme directionnel sont ceux montrés sur la figure 6.5. Ils permettent de régulariser les classes correspondant à des structures linéaires en prenant en compte les étiquettes des pixels dans la direction la plus favorable. En outre, pour préserver les extrémités des lignes, nous considérons les deux orientations opposées  $\text{ori}_s^1$  et  $\text{ori}_s^2$  le long de la direction  $d_s$  d'un site.

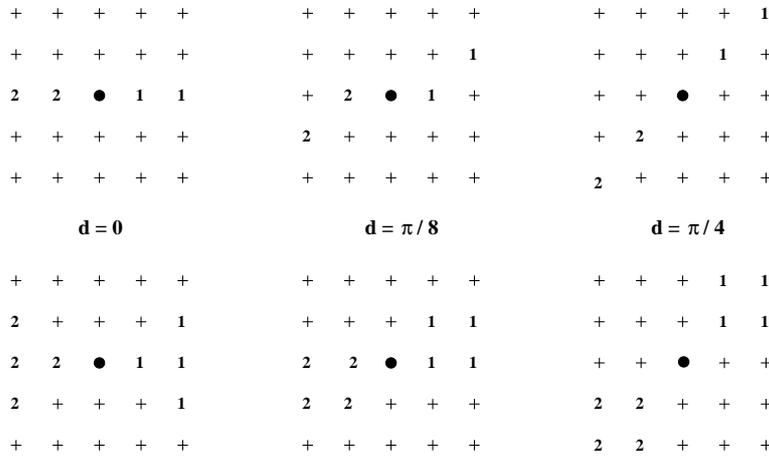


FIG. 6.5 – Voisinages directionnels pour  $0$ ,  $\pi/8$  et  $\pi/4$  (les autres sont déduits par symétrie). Les sites avec le label  $i$  appartiennent à  $\mathcal{V}_{\text{ori}_s^i}$ .

Cette méthode de segmentation markovienne introduit donc un champ externe dont la composante directionnelle permet d'adapter la régularisation à la forme des objets correspondant à chaque classe. Cette préservation des lignes se fait au prix d'une complexité algorithmique accrue puisque le changement de label en un site demande le parcours des sites du voisinage  $\mathcal{V}_s^*$  (une fenêtre 5x5) dont les énergies seront éventuellement modifiées par le changement de label.

Nous avons appliqué cette méthode pour la détection des zones non développables en interférométrie ROS [Trou-96] [Tupi-96c], en particulier les zones de rupture de continuités par sous-échantillonnage qui se caractérisent par les lignes brillantes du relief. Un exemple est montré sur la figure 6.6 comparant les performances avec ou sans modification du terme de régularisation (le terme d'attache aux données "linéaires",  $p(L|E)$ , est utilisé dans les deux cas).

Comme il apparaîtra dans la troisième partie (chapitre 8), l'objectif de la segmentation dans notre application est un simple découpage de l'image (les routes et les lignes de relief étant introduites par une détection préalable). Nous n'avons donc pas inclus cette modification dans la suite.

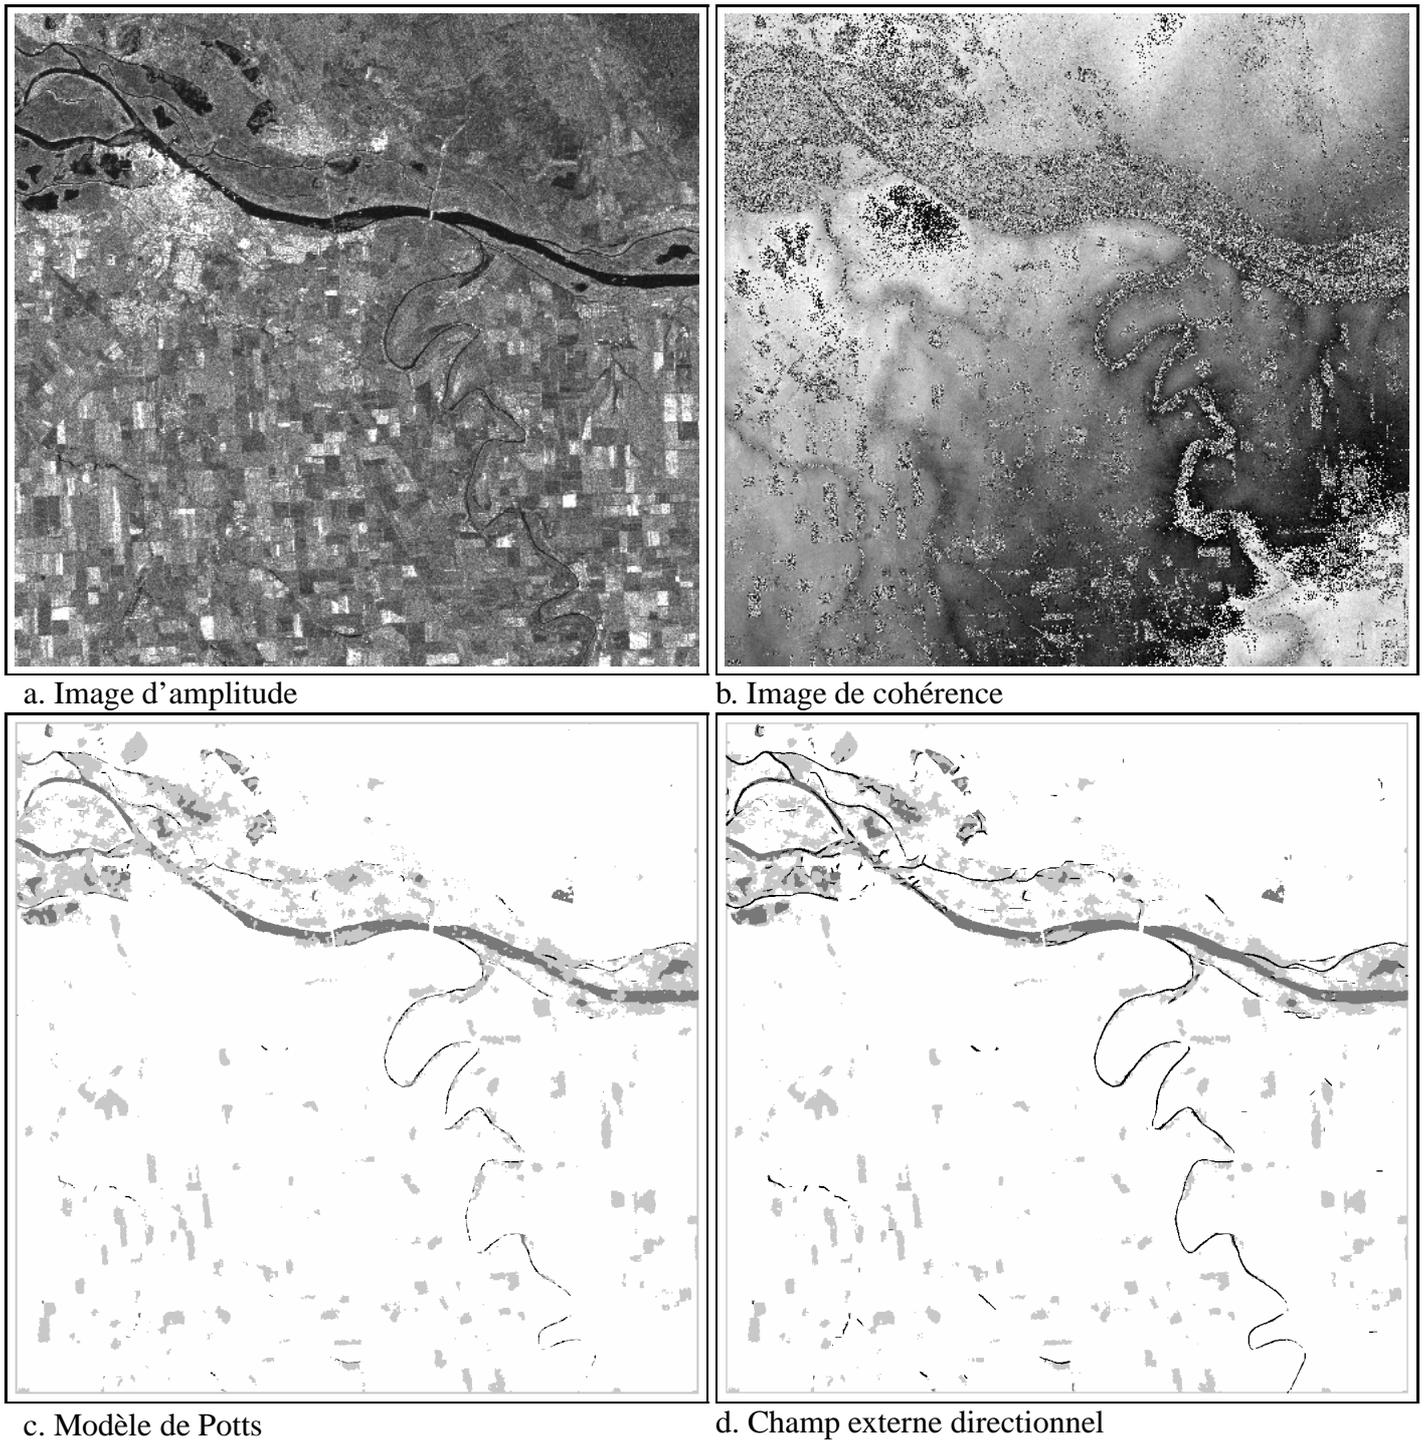


FIG. 6.6 – Comparaison de la régularisation avec le modèle de Potts et le modèle prenant en compte la composante directionnelle du champ pour préserver les structures linéaires (les différentes classes de zones non-développables sont en niveaux de gris)

### 6.3 Détection des zones de parcellaire dense

Nous présentons dans la seconde partie de ce chapitre une application de la détection des zones de parcellaire dense, qui s'appuie sur les régions obtenues par la segmentation.

Celle-ci repose à nouveau sur une modélisation markovienne du problème, le graphe utilisé cette fois étant planaire et à topologie non régulière. Cet outil sera surtout utile pour les régions très agricoles, comme les polders des Pays-Bas.

Le principe de notre démarche est le suivant : nous cherchons dans un premier temps les régions de l'image susceptibles d'être des champs, puis dans un second temps, nous regroupons les champs détectés pour former une région de parcellaire lorsqu'ils sont suffisamment denses dans une zone de l'image.

En réalité, plutôt que de réaliser séparément ces deux étapes, nous proposons de nous placer dans un contexte markovien dont la grande souplesse nous permettra de définir une énergie adaptée à ce problème. En effet, nous pouvons construire un terme d'attache aux données reflétant la "ressemblance" d'une région avec un champ, et un terme contextuel (notre connaissance a priori) favorisant le regroupement de régions pour former le parcellaire dense.

La primitive adaptée à ce problème n'est bien entendu plus le pixel mais une région radiométriquement homogène. Nous proposons donc d'utiliser le résultat de la segmentation exposée précédemment : chaque composante connexe, quelle que soit sa classe, est dorénavant considérée comme une région, et les régions constituent les sites du champ markovien que nous allons définir.

Formalisons maintenant le principe exposé ci-dessus : nous considérons deux étiquettes sur les régions,  $\mathcal{P}$  pour le parcellaire (sous-entendu dense dans toute la suite) et  $\overline{\mathcal{P}}$  pour le non-parcellaire. La relation de voisinage du graphe est la relation d'adjacence entre les régions. Notons  $s$  un site-région,  $S$  l'ensemble des sites,  $L$  le champ d'étiquettes, et  $O$  le champ des observations qui sera défini dans le paragraphe suivant. Un raisonnement similaire à ceux effectués au chapitre 3 et au paragraphe 6.2 permet de munir le champ  $L$  conditionnellement au champ  $O$  d'une structure de champ markovien, moyennant l'hypothèse  $L$  markovien. Celle-ci est là encore justifiée par le fait qu'une connaissance locale autour d'une région nous suffit pour définir un parcellaire dense. Finalement, nous pouvons nous ramener à la minimisation d'une énergie  $U$  :

$$U = \sum_{s \in S} U(O_s | l_s) + \sum_{c \in \mathcal{Cl}} V_c(l)$$

où  $\mathcal{Cl}$  est l'ensemble des cliques.

Il nous faut donc construire une énergie d'attache aux données  $U(O_s | l_s)$  adaptée, et choisir les potentiels des cliques en tenant compte des connaissances a priori que nous avons des classes "parcellaire dense" et "non-parcellaire".

### 6.3.1 Terme d'attache aux données

Contrairement aux applications markoviennes précédentes, nous sortons ici complètement des cadres probabilistes habituels. Tout d'abord, comment définir le champ des observations ? Dans le cas d'une segmentation où les classes sont définies en fonction d'une radiométrie moyenne, le niveau de gris des pixels constitue l'information. La probabilité a posteriori d'un site est alors définie par le modèle statistique choisi. Dans le cas des sites seg-

ments, l'information pertinente est délivrée par les détecteurs de lignes, et un apprentissage permet de définir un modèle probabiliste.

Ici, plusieurs informations interviennent dans la reconnaissance d'une région "champ". Nous avons retenu trois critères qui nous paraissent déterminants : la dimension  $\mathcal{D}$  de la région, sa forme  $\mathcal{F}$ , et la présence de contours  $\mathcal{C}$  sur les frontières qui la délimitent. Une observation  $O_s = (\mathcal{D}_s, \mathcal{F}_s, \mathcal{C}_s)$  est alors définie à partir de ces trois indices, ainsi qu'une énergie  $U(O_s | l_s)$ . Notons qu'il n'y a pas ici de correspondance stricte entre l'énergie et la probabilité a posteriori de l'étiquette  $L_s$  conditionnellement aux observations  $O_s$ . En particulier, nous n'effectuons pas de normalisation, comme c'est fréquemment l'usage en traitement d'images [Desc-95] [Maru-95].

L'énergie  $U(O_s = (\mathcal{D}_s, \mathcal{F}_s, \mathcal{C}_s) | L_s = \mathcal{P})$  est définie de manière à être minimale lorsque les observations correspondent à un champ et maximale dans le cas contraire (inversement pour  $U(O_s | \overline{\mathcal{P}})$ ).

### Définition des indices

- L'indice de dimension  $\mathcal{D}_s$  est simplement défini comme le nombre de pixels qui appartiennent à la région  $O_s$  ( $\mathcal{D}_s \in [0, \mathcal{D}_{max}]$ , où  $\mathcal{D}_{max}$  est la dimension maximale d'une région détectée par la segmentation).
- L'indice de contour est défini par l'application du détecteur de contours Dc1 (cf. §2.2.1) sur les pixels frontières de  $O_s$ . Les réponses sont moyennées et la moyenne constitue l'indice  $\mathcal{C}_s$  ( $\mathcal{C}_s \in [0, 1]$ ).
- L'indice de forme est le plus difficile à définir. Les parcelles agricoles ont a priori une forme géométrique, mais il faut tenir compte de l'imprécision introduite par la segmentation. Tout d'abord, une approximation polygonale des contours des régions est effectuée [Chas-91], puis nous définissons un coût en pénalisant tous les couples de segments qui ne sont pas soit parallèles, soit perpendiculaires :

$$\mathcal{F} = \sum_{(i,j)} \min(\text{Coût}_{i-\epsilon j}, \text{Coût}_{i\parallel\epsilon j})$$

où  $(i, j)$  est un couple de segments appartenant au polygone, et les coûts élémentaires entre deux segments sont :

- $\text{Coût}_{i-\epsilon j} = -1$  si  $i - j$  à  $\epsilon$  près  
 $= 1$  sinon
- $\text{Coût}_{i\parallel\epsilon j} = -1$  si  $i \parallel j$  à  $\epsilon$  près  
 $= 1$  sinon

Ainsi, une région rectangulaire, carrée ou formée de segments parallèles et perpendiculaires a un coût faible. Dans le cas d'un carré par exemple, on considère six couples de segments où les segments sont ou perpendiculaires ou parallèles, et donc le coût global du carré est de -6.

### Définition de l'énergie

La démarche que nous avons adoptée pour définir l'énergie est essentiellement empirique, et s'inspire des ensembles flous [Dubo-88]. En effet, nous proposons de construire des fonctions d'appartenance à l'objet "champ" :  $\mu_D$ ,  $\mu_F$  et  $\mu_C$ , à partir des trois critères précédents. L'énergie sera ensuite déduite en fusionnant ces mesures.

Les fonctions d'appartenance utilisées sont choisies le plus simplement possible, donc linéaires par morceaux. Leurs formes sont déduites des remarques suivantes :

- la taille d'un champ est limitée inférieurement et supérieurement,
- sa forme doit être géométrique donc le coût  $\mathcal{F}$  doit être le plus faible possible,
- il doit avoir des contours nets donc  $\mathcal{C}$  doit être le plus grand possible.

La dernière remarque suppose des cultures variées et donc des champs radiométriquement différents sur l'image. Cette contrainte est légitime car, dans le cas contraire, les champs apparaîtront comme un fond uniforme qu'il ne sera pas possible de détecter. La figure 6.7 montre l'aspect des fonctions d'appartenance associées aux trois indices formant le vecteur des observations, et le tableau 6.2 les seuils utilisés en pratique déduits empiriquement. La taille des champs est supposée comprise entre 100 et 10000 mètres carrés environ. Ces chiffres peuvent bien sûr être modifiés pour s'adapter à un autre type d'agriculture.

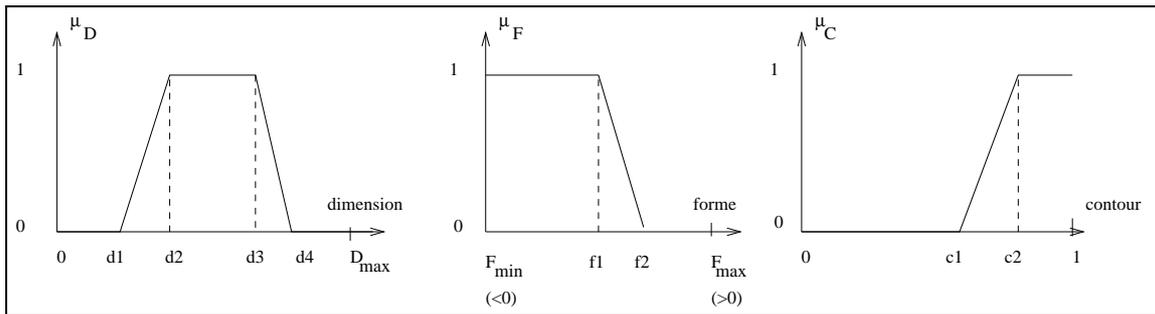


FIG. 6.7 – Allure des fonctions d'appartenance à un objet "champ" ( $D_{max}$  est la dimension maximale d'une région, et  $\mathcal{F}_{min}$  et  $\mathcal{F}_{max}$  les critères de forme minimal et maximal).

TAB. 6.2 – Valeurs des paramètres

d1	d2	d3	d4	f1	f2	c1	c2
100	200	7000	8000	5	10	0,25	0,3

L'énergie est alors définie à l'aide d'un opérateur de fusion  $\mathcal{G}$  sur les trois mesures :

$$\mathcal{G}(\mu_D, \mu_F, \mu_C) = \mu_D \sigma^o(\mu_F, \mu_C) = \frac{\mu_D \mu_F \mu_C}{1 - \mu_F - \mu_C + 2\mu_F \mu_C}$$

Cela revient à fusionner  $\mu_F$  et  $\mu_C$  avec une somme associative symétrique [Bloc-96], de telle sorte que ces mesures se renforcent (cf.§2.7), puis à appliquer un opérateur conjonctif (la multiplication) entre le résultat et la mesure  $\mu_D$ . En effet,  $\mu_D$  est la mesure la plus discriminante des trois, et nous avons donc choisi un opérateur sévère pour la fusionner avec les deux autres.

L'énergie  $U(O_s = (\mathcal{D}_s, \mathcal{F}_s, \mathcal{C}_s)|\mathcal{P})$  devant être minimale lorsqu'il s'agit d'un champ  $(\mathcal{G}(\mu_{\mathcal{D}}, \mu_{\mathcal{F}}, \mu_{\mathcal{C}}))$  est alors maximale, donc proche de 1), nous définissons :

$$\begin{aligned} U(O_s = (\mathcal{D}_s, \mathcal{F}_s, \mathcal{C}_s)|\mathcal{P}) &= \mathcal{N}_s (1 - \mathcal{G}(\mu_{\mathcal{D}}(\mathcal{D}_s), \mu_{\mathcal{F}}(\mathcal{F}_s), \mu_{\mathcal{C}}(\mathcal{C}_s))) \\ U(O_s = (\mathcal{D}_s, \mathcal{F}_s, \mathcal{C}_s)|\overline{\mathcal{P}}) &= \mathcal{N}_s \mathcal{G}(\mu_{\mathcal{D}}(\mathcal{D}_s), \mu_{\mathcal{F}}(\mathcal{F}_s), \mu_{\mathcal{C}}(\mathcal{C}_s)) \end{aligned}$$

où  $\mathcal{N}_s$  est le nombre de régions adjacentes au site-région  $s$ . Cette pondération par  $\mathcal{N}_s$  est nécessaire pour que le terme d'attache aux données et le terme contextuel (voir le paragraphe suivant) aient le même poids, quel que soit le nombre de régions adjacentes à  $s$ . Nous pourrions également envisager une pondération en fonction de la taille des régions.

### 6.3.2 Terme contextuel

Il s'agit ici de définir les potentiels des cliques du champ des étiquettes  $L$  que nous supposons markovien. L'information a priori que nous souhaitons introduire est qu'une région étiquetée "parcellaire dense" ne peut être isolée, les régions voisines devant donc avoir la même étiquette. Nous ne tiendrons compte dans cette application que des cliques d'ordre deux dont nous définissons les potentiels conformément à la remarque précédente par :

$$\begin{aligned} \bullet V_{c=(s,t)}(l) &= -\beta_{\mathcal{P}} \text{ si } l_s = l_t = \mathcal{P} \\ \bullet V_{c=(s,t)}(l) &= -\beta_{\overline{\mathcal{P}}} \text{ si } l_s = l_t = \overline{\mathcal{P}} \\ \bullet V_{c=(s,t)}(l) &= 0 \text{ dans les autres cas} \end{aligned}$$

Ce modèle est proche du modèle du Potts, mais permet de choisir des constantes différentes pour les deux classes, parcellaire et non-parcellaire.

### 6.3.3 Résultats

Un algorithme de relaxation stochastique, l'échantillonneur de Gibbs, est ensuite appliqué pour classer les régions de la segmentation. Les résultats sur deux régions de Polders sont montrés figure 6.8. Ceux obtenus sur d'autres zones moins agricoles dont nous disposons ne sont pas présentés puisqu'aucune région de parcellaire dense n'est alors détectée, les champs visibles sur l'image apparaissant souvent comme isolés.

La méthode proposée est cependant limitée sur plusieurs aspects. Tout d'abord, le positionnement n'est pas toujours très satisfaisant, certains endroits apparaissant plutôt comme homogènes (fig. 6.8b, en bas à droite). D'autre part, cette technique suppose des champs très bien délimités, ou tout au moins contrastés, ce qui n'est bien sûr pas toujours le cas. En effet, si tous les champs sont cultivés de la même façon, il est probable qu'ils apparaîtront sous forme d'un fond pratiquement uniforme sur l'image. C'est une des raisons pour lesquelles aucun parcellaire dense n'est détecté sur la région de Lorient (alors qu'il s'agit d'une zone relativement agricole), comme c'est aussi le cas sur la partie basse de l'image de Lelystad.

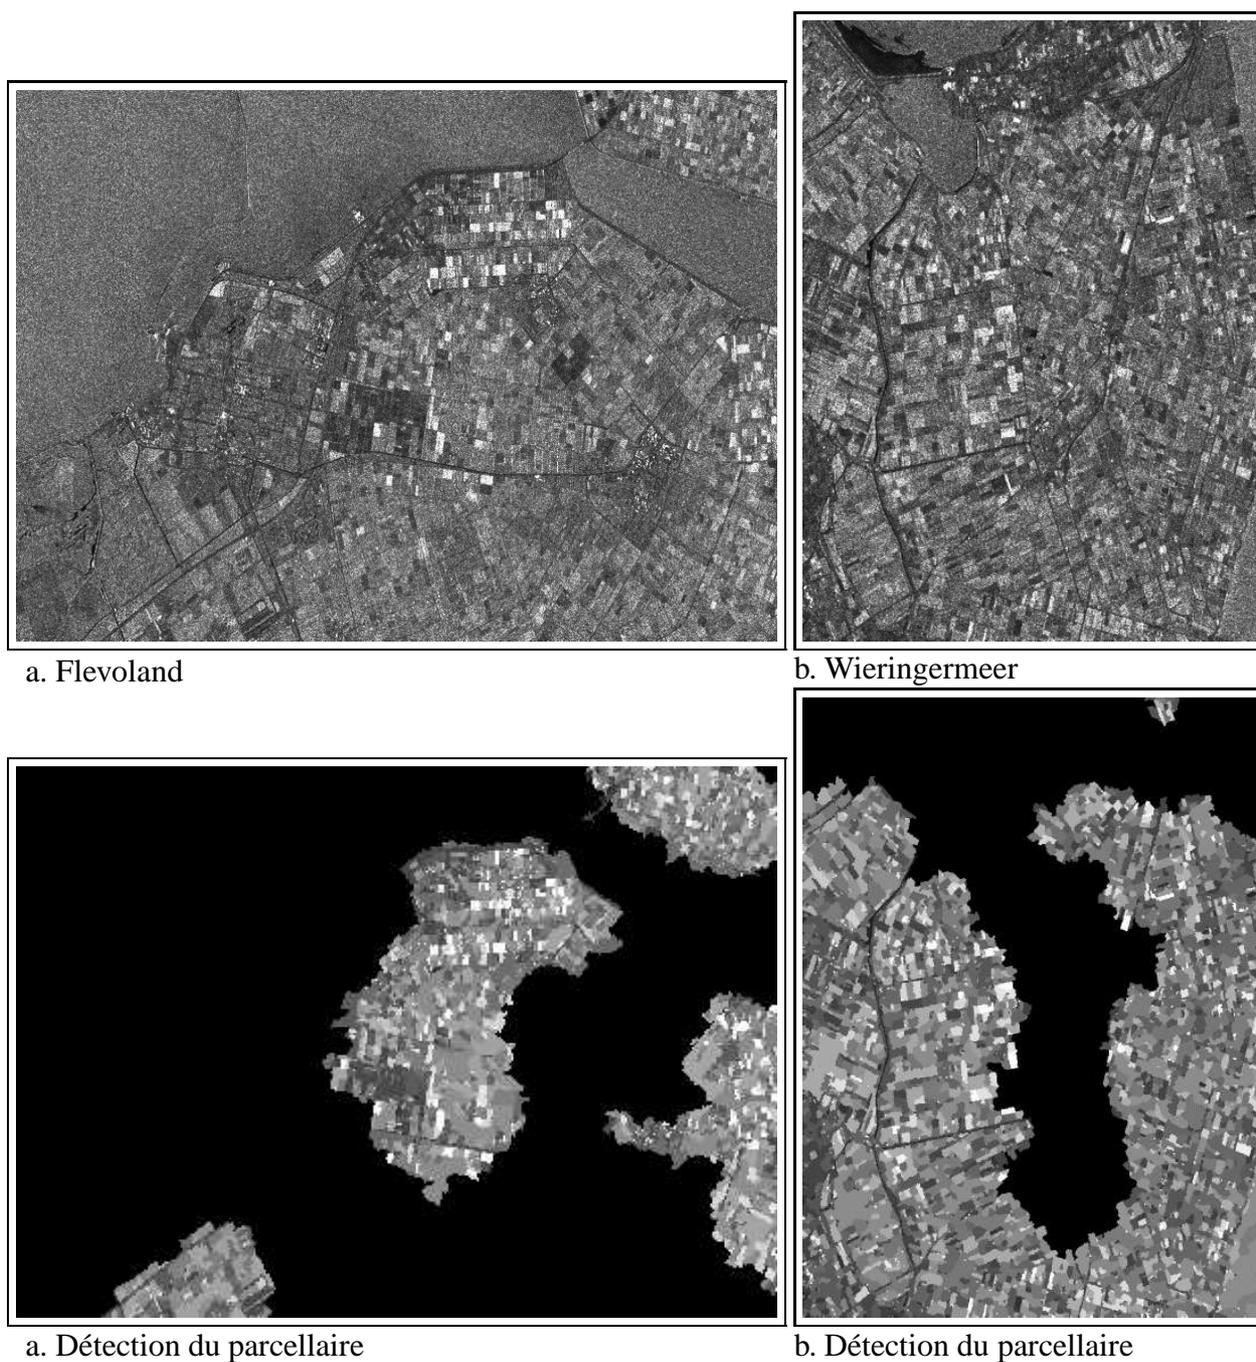


FIG. 6.8 – Images originales ©ESA (en haut, cf. annexe A.2) et détection des zones de non parcellaire (en noir) et des zones de parcellaire (les régions classées "champs" sont affichées en niveaux de gris).

## 6.4 Conclusion

Dans la première partie de ce chapitre, nous avons présenté une méthode markovienne de segmentation des images ROS et proposé d'introduire un champ externe avec composante directionnelle pour une meilleure préservation des classes linéaires. Les résultats obtenus,

délimitant des régions radiométriquement homogènes, suffisent à notre objectif d'interprétation globale de l'image radar. Nous avons également indiqué quelles étaient les techniques qui permettraient de rendre cette étape totalement automatique, que ce soit pour l'estimation des paramètres des classes ou de leur nombre. A titre de prospective, il serait également intéressant d'exploiter les résultats obtenus aux différentes résolutions, que ce soit directement en les fusionnant, en initialisant une segmentation à partir d'une autre, ou en utilisant toutes les résolutions lors du recuit simulé. Ainsi, l'utilisation de méthodes réellement hiérarchiques comme celles proposées par Pérez [Pere-93] et Kato [Kato-94] [Graf-95] devrait apporter des améliorations. Le formalisme cohérent qu'elles proposent permettraient non seulement une réelle exploitation du multi-échelles -avec collaboration entre les différents niveaux (qui n'a pas été faite ici)-, mais aussi une accélération de la segmentation.

Dans la seconde partie de ce chapitre, nous avons proposé une première utilisation originale de la segmentation pour la détection des zones de parcellaire dense en définissant un champ markovien sur des régions.

Ce chapitre et plus précisément la méthode de segmentation présentée seront nécessaires pour le schéma global d'interprétation qui est proposé dans la troisième partie. Notre contribution au problème général de la segmentation des images radar est cependant minime, et seules l'introduction d'un champ externe pour une meilleure préservation des structures linéaires et l'application à la détection du parcellaire dense sont originales. En réalité, la segmentation utilisée pourrait sans doute être avantageusement remplacée par une méthode plus performante comme celle de Fjortoft *et al.* [Fjor-97] ou Marzouki [Marz-96].

## Chapitre 7

# Texture en imagerie radar

*Ce chapitre se décompose en deux parties : la première concerne les discriminateurs texturaux utilisés en imagerie radar, et la seconde deux méthodes dédiées plus spécifiquement au milieu urbain. Ainsi, la première partie présente quelques techniques d'analyse de texture, et en particulier trois d'entre elles qui ont été testées sur différentes images ERS-1. Les deux premières méthodes reposent sur les statistiques du premier ordre ; il s'agit, d'une part, du calcul et de la combinaison de certains moments (moyenne, coefficient de variation...) et, d'autre part, de la décomposition de l'histogramme à l'aide des polynômes de Laguerre [Beau-92]. Quant à la troisième mesure, elle s'appuie sur le modèle auto-régressif multiplicatif proposé par Frankot et Chellappa [Fran-87]. Nous montrons comment cette dernière méthode peut être utilisée pour la détection des zones homogènes (mer ou forêt) et des zones industrielles. La seconde partie de ce chapitre décrit deux méthodes dédiées plus spécifiquement à la détection du milieu urbain sur les images radar. La première a été proposée par Gouinaud [Goui-96b] pour les zones d'urbain dense et nous en redonnons le principe ici. La seconde est consacrée à la discrimination des zones plus industrielles et elle est fondée sur la répartition des points brillants dans l'image.*

### 7.1 Discriminateurs texturaux en imagerie radar

La texture d'une région est une information importante dans tout processus de classification puisque ses caractéristiques nous renseignent sur la répartition spatiale des niveaux de gris. Nous allons aborder dans ce chapitre quelques discriminateurs texturaux qui viendront s'ajouter aux autres outils développés pour l'interprétation automatique de la scène. Précisons que l'objectif poursuivi dans ce travail n'est pas à proprement parler la classification automatique des images, mais plus modestement d'obtenir une information sur la texture des régions. Aussi, ne disposons nous pas de base de données d'échantillons et les performances des discriminateurs ne sont pas évaluées de façon automatique. Seules des petites images tests présentant des cas extrêmes, zones sans texture et très texturées (découpées manuellement), serviront à l'analyse des discriminateurs. Des applications visant à segmenter des régions particulièrement homogènes, comme l'eau calme ou certaines zones de végétation (§7.1.4), et des régions très hétérogènes comme les zones industrielles (§7.1.5), viendront

compléter l'étude des différents discriminateurs. Par ailleurs, la recherche de discriminateurs texturaux appropriés aux images radar pourrait nécessiter, en soi, toute une thèse. Nous nous contentons ici de tester des discriminateurs texturaux déjà proposés (§7.1.1 et §7.1.2), ou de généraliser des méthodes existantes au type de données dont nous disposons (§7.1.1). Dans un second temps nous présentons deux méthodes dédiées spécifiquement au milieu urbain (§7.2).

L'analyse de texture est un vaste champ d'investigation du traitement d'images dans les domaines d'applications les plus variés (synthèse d'images, télédétection, imagerie médicale...). On distingue généralement plusieurs familles de méthodes. Pour exemples, citons tout d'abord les méthodes statistiques, que ce soient celles du premier ordre (moyenne, écart-type, coefficient de dissymétrie, d'aplatissement...) analysant la distribution des niveaux des gris, ou celles du second ordre [Hara-73] [Wesz-76] (fonction d'auto-corrélation et matrices de co-occurrences) permettant la modélisation des relations spatiales entre pixels. Signalons ensuite la famille des méthodes dites géométriques qui s'appuient sur l'extraction d'éléments de textures ou de primitives et sur l'analyse de leur organisation [Blos-89]. Notons, enfin, les méthodes fondées sur une modélisation du signal [Habi-72] (modèle auto-régressif, markovien gaussien, fractal [Mart-96] [Falc-96]...), les paramètres du modèle servant alors à caractériser la texture.

Nous avons sélectionné seulement trois méthodes d'analyse de texture que nous décrivons dans la suite de ce chapitre. En tout premier lieu, nous étudierons les statistiques du premier ordre, en particulier le coefficient de variation très souvent utilisé en raison de sa simplicité et de ses fondements théoriques. Ensuite, nous envisagerons une deuxième technique également basée sur les statistiques du premier ordre. Elle reprend l'idée de Beaupère qui proposait une décomposition de l'histogramme local [Beau-92], en la généralisant aux images d'amplitude multi-vues. Notre choix a été guidé par les conclusions de [Goui-96] préconisant l'utilisation de l'histogramme pour la détection des zones urbaines. Enfin, nous nous intéresserons à la modélisation de l'image par un modèle auto-régressif multiplicatif [Fran-87], technique choisie conformément aux conclusions de Schistad [Schi-95] qui lui attribuait les meilleurs résultats dans une étude comparative portant sur des images ERS-1. Pour chacune de ces méthodes, des résultats seront présentés sur les images d'Aix, de Kourou et du Flevoland. Ces trois méthodes seront comparées et un bilan de leurs avantages et inconvénients sera présenté dans la section 7.1.3.

### 7.1.1 Statistiques du premier ordre

Elles ont été beaucoup utilisées pour la classification des images radar. Si l'information tonale de la moyenne a été reconnue comme non-significative lorsqu'elle est utilisée seule [Barb-93], le coefficient de variation  $\gamma$  s'est, en revanche, révélé beaucoup plus adapté [Laur-87] [Laur-89] [Beau-92]. Ce résultat se déduit logiquement des expressions de  $\gamma$  obtenues au chapitre 1 pour les zones de chatoiement totalement développé. En effet, il possède alors une valeur parfaitement définie ne dépendant que du nombre de vues (théorique ou équivalent). Le coefficient de variation calculé localement a donc été utilisé comme mesure d'hétérogénéité; sa valeur varie du seuil bas théorique des équations 1.2 ou 1.5, sur les zones très homogènes, à des valeurs élevées sur le milieu urbain, en prenant des valeurs

intermédiaires sur les zones de forêts moyennement texturées.

La figure 7.1 montre les résultats du calcul du coefficient de variation local sur une fenêtre  $11 \times 11$  pour des images codées sur 16 bits. Pour pouvoir comparer les images obtenues, la dynamique a été étalée entre les valeurs 0 et 1 pour  $\gamma$ , la valeur théorique pour une zone de chatoiement totalement développé étant d'environ 0,3 (en 3-vues). On constate une détection des contours des champs (fig.7.1c) et des zones urbaines (fig.7.1b), bien que la localisation soit détériorée par le phénomène de blocs dû à la fenêtre  $11 \times 11$  (fig.7.1a). D'autre part, des seuillages multiples n'ont pas montré l'apparition d'une classe de texture intermédiaire qui serait liée aux forêts, à mi-chemin entre les zones de chatoiement totalement développé et les zones industrielles. Ces résultats décevants par rapport aux conclusions de Laur [Laur-89] ou de Beaupère [Beau-92], mais confirmés par Schistad [Schi-95], s'expliquent certainement par la résolution des images ERS-1. En effet, la texture des forêts, due à la juxtaposition de la partie rétrodiffusante et de la partie à l'ombre de l'arbre, n'est en réalité plus visible à une résolution effective de 25m [Shan-81] [Laur-89], et celles-ci apparaissent homogènes.

D'autres statistiques du premier ordre ont été utilisées, notamment le coefficient de dissymétrie  $\beta_1$  (skewness) et d'aplatissement  $\beta_2$  (kurtosis), mais ils se sont révélés moins intéressants que le coefficient de variation [Laur-89], ou tout au plus d'intérêt comparable [Schi-95]. Le problème de ces statistiques utilisant des moments d'ordre plus élevés que  $\gamma$  (respectivement ordre 3 et 4) est qu'elles nécessitent de grandes tailles d'échantillons pour que leur estimation soit fiable [Laur-89] [Goui-96b]. Or, si nous faisons une estimation locale en chaque point, nous avons de plus en plus de risques d'intégrer des pixels appartenant à des régions différentes lorsque nous augmentons la taille de la fenêtre d'analyse (ce problème est discuté dans le paragraphe suivant). Néanmoins, lorsqu'il est possible de travailler sur de grandes zones présentant la même texture (images radar de l'océan, par exemple), ces statistiques permettent des discriminations correctes. L'utilisation des distributions du système de Pearson a été proposée [Deli-97] [Quel-93], les paramètres  $\beta_1$  et  $\beta_2$  permettant de choisir la distribution la plus adaptée, ou de classifier directement le type de mer (agitée, calme, présence de glace...) [Deli-97]. Par ailleurs, le calcul des statistiques sur des régions radiométriquement homogènes, obtenues par une segmentation préalable (cf. chapitre 6), a donné des résultats décevants. Cela s'explique par le fait que la segmentation sépare les primitives des textures très hétérogènes, ce qui donne par la suite des statistiques proches pour toutes les régions.

Nous faisons une parenthèse ici pour éclaircir la notion de texture et discuter le problème du choix de la fenêtre d'analyse pour le calcul des statistiques. En effet, des solutions pourraient s'inspirer de celles proposées pour le filtrage (cf. chapitre 5). Ainsi, on pourrait envisager de faire une croissance de fenêtre en chaque pixel comme proposé par Wu et Maître [Wu-92]. Mais se pose alors le problème du critère de croissance puisque cette fois-ci les zones ne sont plus supposées homogènes mais texturées. Plus précisément, un fort réflecteur doit-il par exemple être considéré comme un composant de la texture de la ville (au même titre que ses pixels voisins) ou être détecté isolément? Les méthodes de détection de structures [Lope-93b] se heurtent au même problème. Nous pensons qu'une bonne solution serait de hiérarchiser les textures à détecter. Les textures très hétérogènes, comme la ville et le milieu urbain, ou très homogènes, peuvent être détectées par une première analyse de

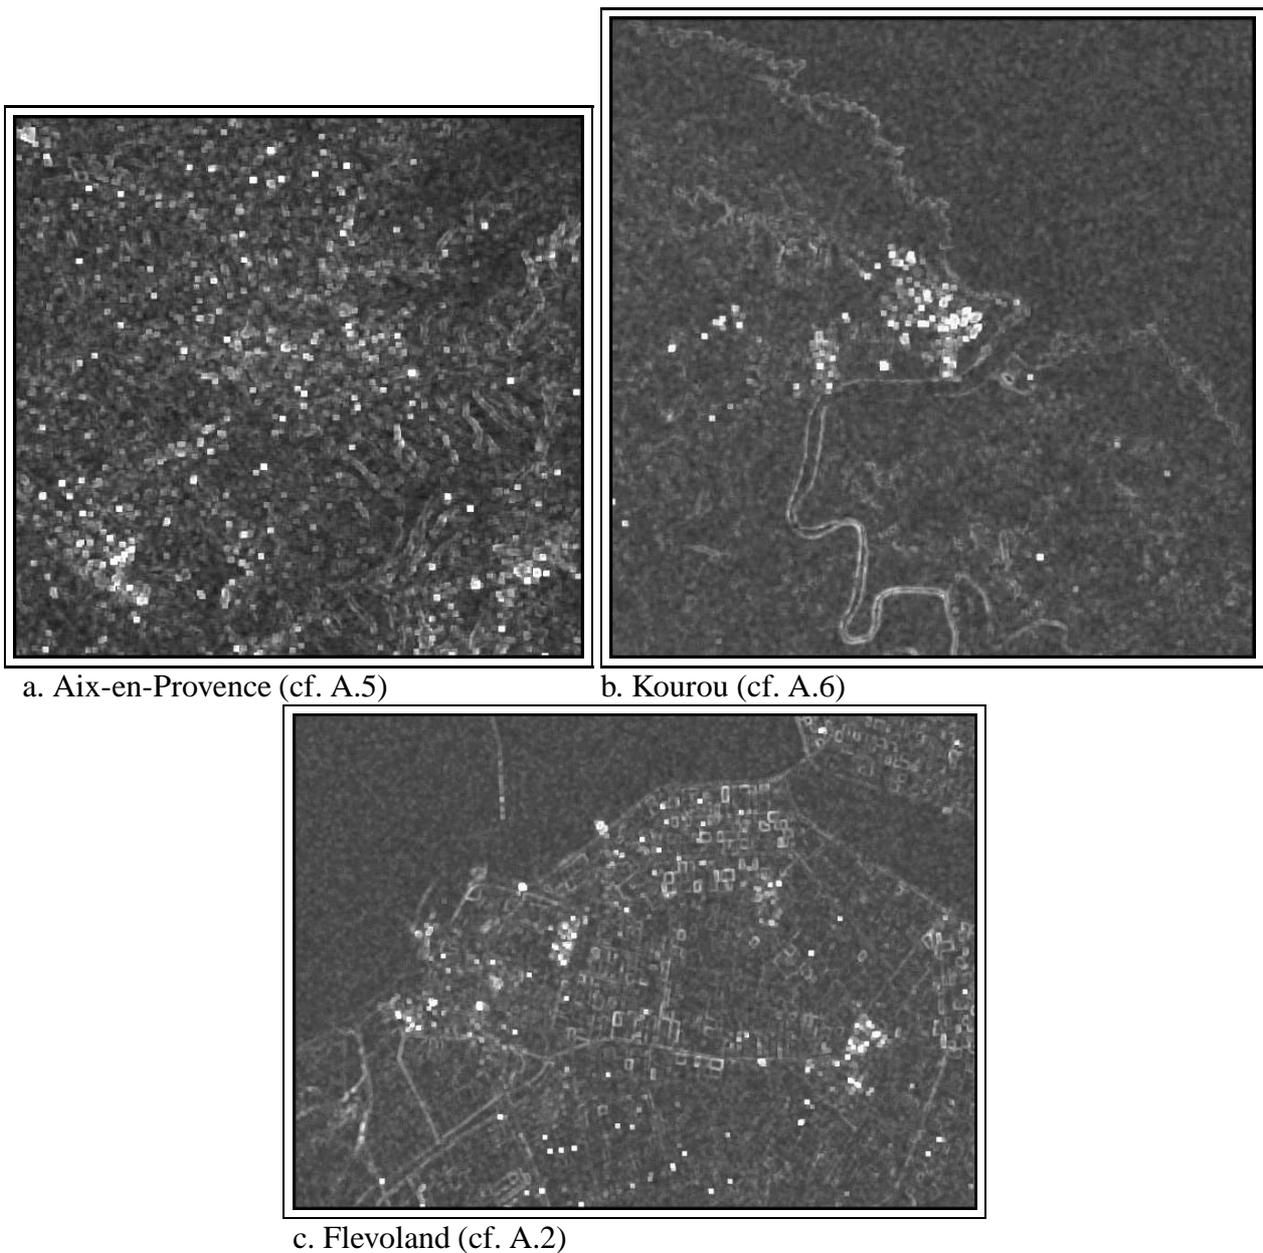


FIG. 7.1 – Coefficient de variation calculé localement sur une fenêtre de taille  $11 \times 11$

textures (en utilisant par exemple une des deux méthodes proposées ci-dessous). Ensuite, une seconde discrimination, plus fine, couplée avec une segmentation ou une détection de contours et de lignes devrait permettre une discrimination des différentes sortes de végétation (même si la tentative évoquée précédemment ne nous a pas paru convaincante). En réalité, notre objectif dans ce chapitre est d'étudier le premier niveau (grossier) de cette discrimination texturale, et nous nous intéresserons donc particulièrement à la discrimination des zones très hétérogènes et très homogènes.

Outre les statistiques évoquées précédemment, une nouvelle mesure d'hétérogénéité a également été proposée dans [Beuc-96]. Elle consiste à calculer localement le rapport entre

la moyenne arithmétique et géométrique de l'intensité. En effet, Oliver [Oliv-94b] a montré que  $\ln \hat{I} - \widehat{\ln I}$  (en notant  $\hat{x}$  l'estimation de  $x$ ) déterminait le paramètre d'ordre de la distribution Gamma suivie par la scène sous-jacente  $R$  (on a alors une distribution K pour l'image radar, cf. chapitre 1). Les résultats obtenus avec ce nouvel indice sont sensiblement meilleurs que ceux du coefficient de variation, et font ressortir plus nettement les hétérogénéités de la scène, que ce soient les milieux industriels ou les structures (contours, lignes et réflecteurs isolés).

Enfin, de nombreux auteurs préconisent l'utilisation des statistiques du deuxième ordre plutôt que du premier, que ce soit par le calcul de la fonction d'auto-corrélation [Ulab-86] ou en utilisant les matrices de co-occurrence [Shan-81] [Barb-93] [Trei-96] [Soh-96]. Nous n'avons pas testé ces méthodes car elles donnaient de moins bons résultats que la méthode de la section 7.1.3 dans l'étude comparative de Schistad [Schi-95].

### 7.1.2 Décomposition de l'histogramme à l'aide de polynômes de Laguerre

Nous nous proposons ici d'analyser les caractéristiques texturales d'une région à l'aide de son histogramme  $h(x)$ . Si nous étions dans les conditions du chatoiement totalement développé, celui-ci suivrait une loi gamma généralisée,  $f_\chi(x)$ . Partant de cette constatation, nous cherchons à mesurer l'éloignement (le biais) éventuel de l'histogramme par rapport à cette référence qui caractérise une zone homogène. En adaptant la démarche de Beaupère sur des images 1-vue [Beau-92], nous étudions donc une décomposition de l'histogramme sur une base de fonctions orthogonales  $F_k(x)$  sous la forme :

$$h(x) = \sum_{k=0}^N \alpha_k f_\chi(x) P_k(x) = \sum_{k=0}^N \alpha_k F_k(x) \quad (7.1)$$

où les  $P_k(x)$  sont des polynômes répondant à la contrainte suivante (en notant  $\delta$  le symbole de Kronecker) :

$$\int_0^{+\infty} f_\chi^2(x) P_i(x) P_j(x) dx \propto \delta_{ij}$$

Comme  $f_\chi$  s'écrit (éq.1.4) :

$$f_\chi(x) = K x^{2L-1} e^{-\frac{Lx^2}{2\sigma^2}}$$

avec  $K = \frac{2L^L}{\Gamma(L)(2\sigma^2)^L}$ , nous cherchons des polynômes satisfaisant :

$$\int_0^{+\infty} x^{2(2L-1)} e^{-\frac{Lx^2}{\sigma^2}} P_i(x) P_j(x) dx \propto \delta_{ij}$$

Montrons que les polynômes de Laguerre vérifient cette contrainte. Nous savons déjà qu'ils ont pour propriété [Ayan-71] :

$$\int_0^{+\infty} x^\alpha e^{-x} L_m^\alpha(x) L_n^\alpha(x) dx = n! (\alpha + n)! \delta_{nm} \quad (7.2)$$

Ainsi, en faisant le changement de variable  $x = \frac{Lu^2}{\sigma^2}$ , en posant  $\alpha = 2L - \frac{3}{2}$  et en utilisant  $\Gamma(j+1) = j!$  dans l'équation 7.2, on obtient la relation suivante :

$$\int_0^{+\infty} f_\chi^2(u) L_n^{2L-\frac{3}{2}}\left(\frac{Lu^2}{\sigma^2}\right) L_m^{2L-\frac{3}{2}}\left(\frac{Lu^2}{\sigma^2}\right) du = \frac{\sqrt{L}}{\Gamma(L)^2 2^{2L-1} \sigma} \Gamma(n+1) \Gamma(2L - \frac{1}{2} + n) \delta_{nm}$$

Celle-ci nous amène naturellement au choix  $P_k(x) = L_k^{2L-\frac{3}{2}}\left(\frac{Lx^2}{\sigma^2}\right)$ , les polynômes de Laguerre  $L_n^\alpha(x)$  étant définis à partir de la formule de récurrence :

$$\begin{aligned} L_0^\alpha(x) &= 1 \text{ et } L_1^\alpha(x) = \alpha + 1 - x \\ L_{n+1}^\alpha(x) &= (2n + \alpha + 1 - x)L_n^\alpha(x) - n(n + \alpha)L_{n-1}^\alpha(x) \end{aligned}$$

Ce résultat est conforme à celui de Beaupère [Beau-92] qui trouvait dans le cas monovue d'une loi de Rayleigh  $P_k(x) = L_k^{\frac{1}{2}}\left(\frac{x^2}{\sigma^2}\right)$ .

L'orthogonalité des fonctions  $F_k$  permet un calcul simple des coefficients intervenant dans la décomposition 7.1, qui sont alors donnés par :

$$\alpha_k = \frac{\Gamma(L)^2 2^{2L-1} \sigma}{\sqrt{L} \Gamma(k+1) \Gamma(2L - \frac{1}{2} + k)} \int_0^{+\infty} h(x) F_k(x) dx$$

Dans le cas d'une zone homogène où  $h(x) = f_\chi(x)$ , on obtient  $\alpha_0 = 1$  et  $\alpha_k = 0 \forall k \neq 0$ . Par conséquent, l'écart par rapport à la loi gamma généralisée théorique est mesuré par l'écart par rapport à 1 de  $\alpha_0$ , et l'écart par rapport à 0 des autres coefficients.

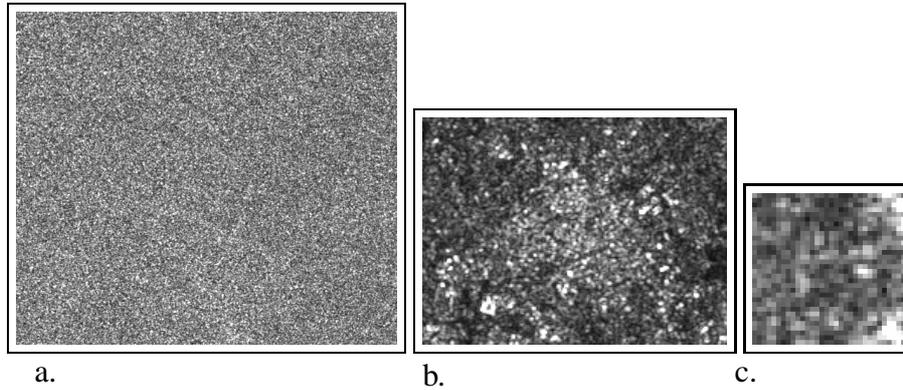


FIG. 7.2 – Trois petites images tests : a. image de mer  $540 \times 480$ , b. image de ville  $200 \times 150$ , c. image d'une zone hétérogène  $32 \times 32$

Cette méthode est tout d'abord illustrée sur les trois zones tests de la figure 7.2. Les étapes intermédiaires du processus de décomposition sont présentées sur les figures 7.3, 7.4 et 7.6 qui montrent la déformation progressive de la distribution de référence (loi gamma généralisée) suivant le nombre de coefficients  $N$  considéré. Par ailleurs, les fonctions  $\alpha_k F_k(x)$  sont tracées figure 7.5 pour l'image de ville (fig.7.2b.). Même pour les zones très hétérogènes, on constate visuellement un appariement satisfaisant entre l'histogramme lissé et

le résultat de la décomposition, en particulier pour la queue de la distribution. Par contre, comme illustré sur la figure 7.6, il est parfois nécessaire de tenir compte d'un grand nombre de coefficients (huit dans ce cas). Nous nous limiterons ici à huit coefficients, ceux d'ordre plus élevé étant presque toujours nuls.

Cette technique de décomposition permet de concentrer l'information contenue dans l'histogramme d'une région à la connaissance de neuf paramètres : les huit coefficients  $\alpha_k$ , et  $\sigma$  obtenu à partir de la moyenne locale par (§1.3.3) :

$$\mu_{A_L} = \frac{\Gamma(L + 0, 5)}{\sqrt{L}\Gamma^2(L)} \sqrt{2}\sigma$$

Pour une classification automatique de la scène, il serait intéressant d'utiliser une méthode de k-moyennes sur ces vecteurs, en choisissant une distance adaptée<sup>1</sup> et une base significative d'apprentissage. En l'absence de base de données, nous avons tenté d'exploiter plusieurs combinaisons de ces coefficients pour distinguer non pas seulement les zones très hétérogènes (pour lesquelles  $\alpha_0$  devient très faible) et les zones très homogènes (pour lesquelles  $\alpha_0$  est proche de 1), mais également l'urbain dense, qui présente une certaine homogénéité, et les zones faiblement texturées. En l'absence de base de données qui nous permettrait d'obtenir des vecteurs significatifs, nous n'avons aucun résultat concluant. L'information contenue dans les coefficients d'ordre élevé, pourtant primordiale dans la forme finale de l'approximation de l'histogramme (fig.7.6), semble difficilement exploitable.

Sur un plan plus pratique, cette technique est très coûteuse en temps de calcul. En effet, nous avons choisi dans un premier temps de conserver la dynamique de 16 bits de l'image tout en effectuant un moyennage de l'histogramme. La taille de la fenêtre d'analyse pour construire l'histogramme est de  $32 \times 32$  pixels, et seulement un point sur huit en lignes et en colonnes est traité, donnant un résultat dont la résolution est fortement dégradée. Une réduction du nombre de valeurs de l'histogramme à 512 a entraîné une légère dégradation du résultat avec une variation parfois significative des coefficients  $\alpha_k$ . Par ailleurs, la taille de la fenêtre d'analyse ne permet la discrimination que de zones de grandes dimensions, ce qui limite l'utilisation d'une telle méthode. La figure 7.7 montre les images des trois premiers coefficients de la décomposition sur les zones d'Aix, de Kourou et du Wieringermeer.

### 7.1.3 Modèle multiplicatif auto-régressif (MAR)

Ce modèle, proposé dans [Fran-87], donne les meilleurs résultats de classification automatique sur des images ERS-1 dans l'étude comparative de Schistad [Schi-95]. Nous le reprenons donc ici. De plus, contrairement aux discriminateurs texturaux précédemment décrits, il fait intervenir les relations spatiales entre pixels.

---

1. Il est en effet probable qu'une distance euclidienne ne soit pas optimale puisque les coefficients de la décomposition décroissent naturellement mais ont une influence de plus en plus grande sur la queue de la distribution.

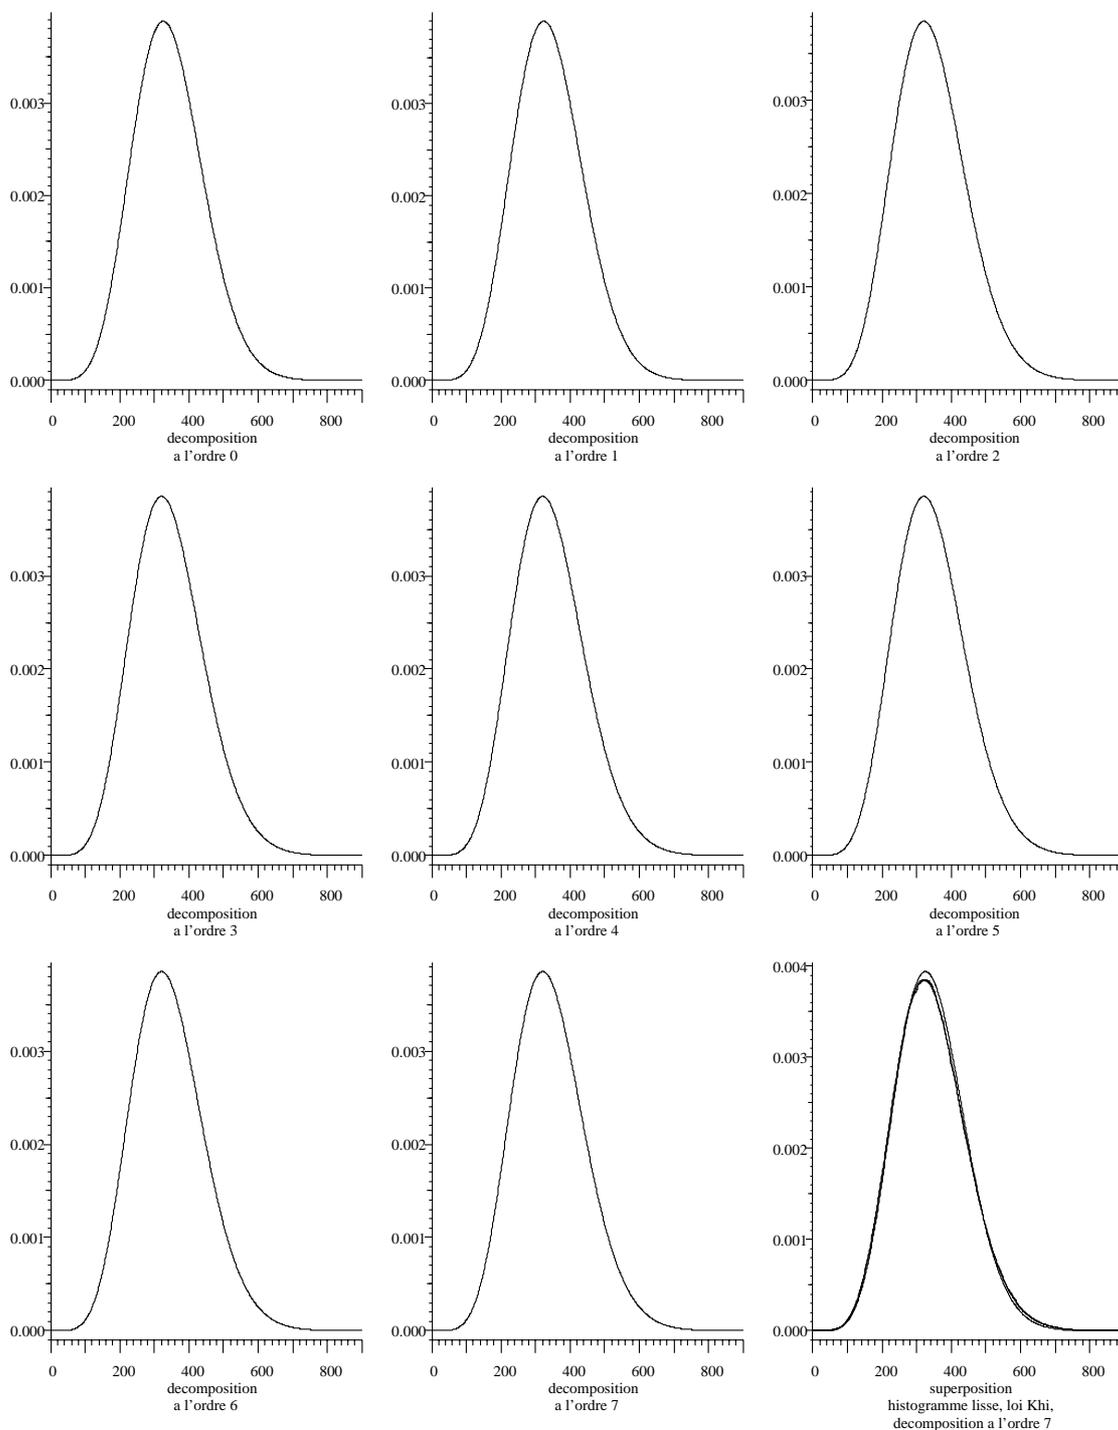


FIG. 7.3 –  $\sum_{k=0}^N \alpha_k F_k(x)$  pour différents ordres  $N$  (de 0 à 7) sur l'imagette de mer homogène et superposition de l'histogramme lissé, de la loi gamma généralisée (notée  $\chi$ ) et du résultat de la décomposition à l'ordre 7

$\alpha_0$	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	$\alpha_6$	$\alpha_7$
$9,85 \cdot 10^{-1}$	$5,67 \cdot 10^{-3}$	$2,84 \cdot 10^{-3}$	$-9 \cdot 10^{-6}$	$< 10^{-7}$	$< 10^{-7}$	$< 10^{-7}$	$< 10^{-7}$

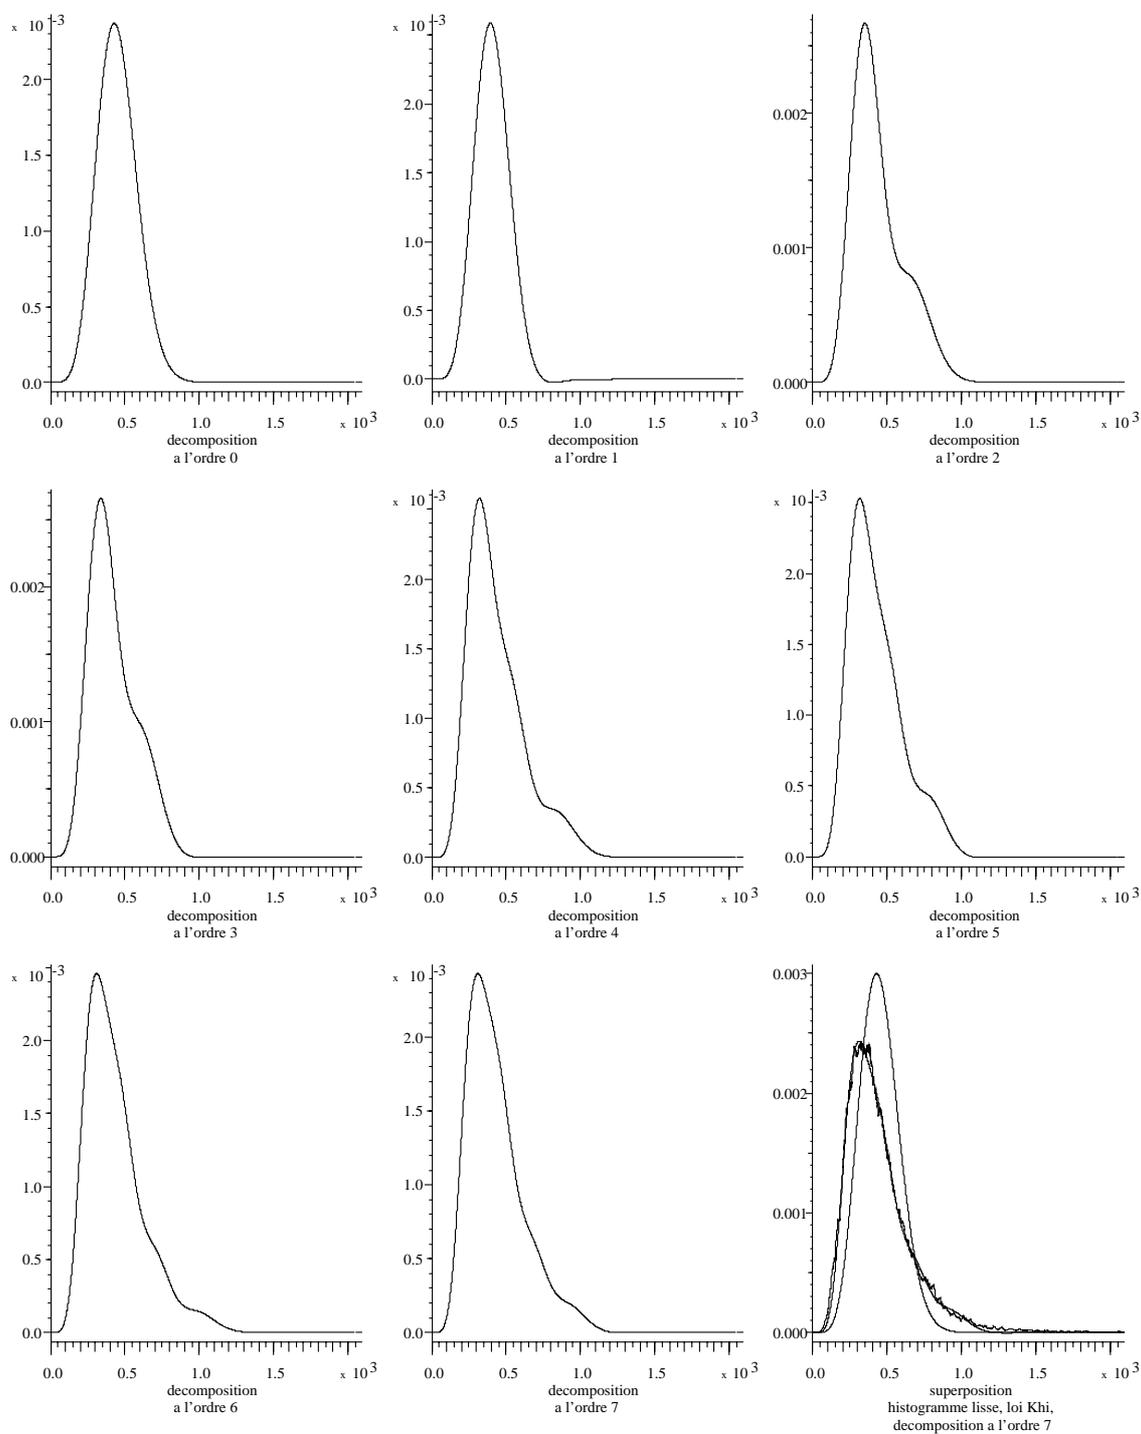


FIG. 7.4 –  $\sum_{k=0}^N \alpha_k F_k(x)$  pour différents ordres  $N$  (de 0 à 7) sur l'imagette de zone urbaine et superposition de l'histogramme lissé, de la loi gamma généralisée (notée  $\chi$ ) et du résultat de la décomposition à l'ordre 7

$\alpha_0$	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	$\alpha_6$	$\alpha_7$
$7,91 \cdot 10^{-1}$	$7,94 \cdot 10^{-2}$	$2,93 \cdot 10^{-2}$	$1,84 \cdot 10^{-3}$	$4,36 \cdot 10^{-4}$	$2,5 \cdot 10^{-5}$	$4,0 \cdot 10^{-6}$	$< 10^{-7}$

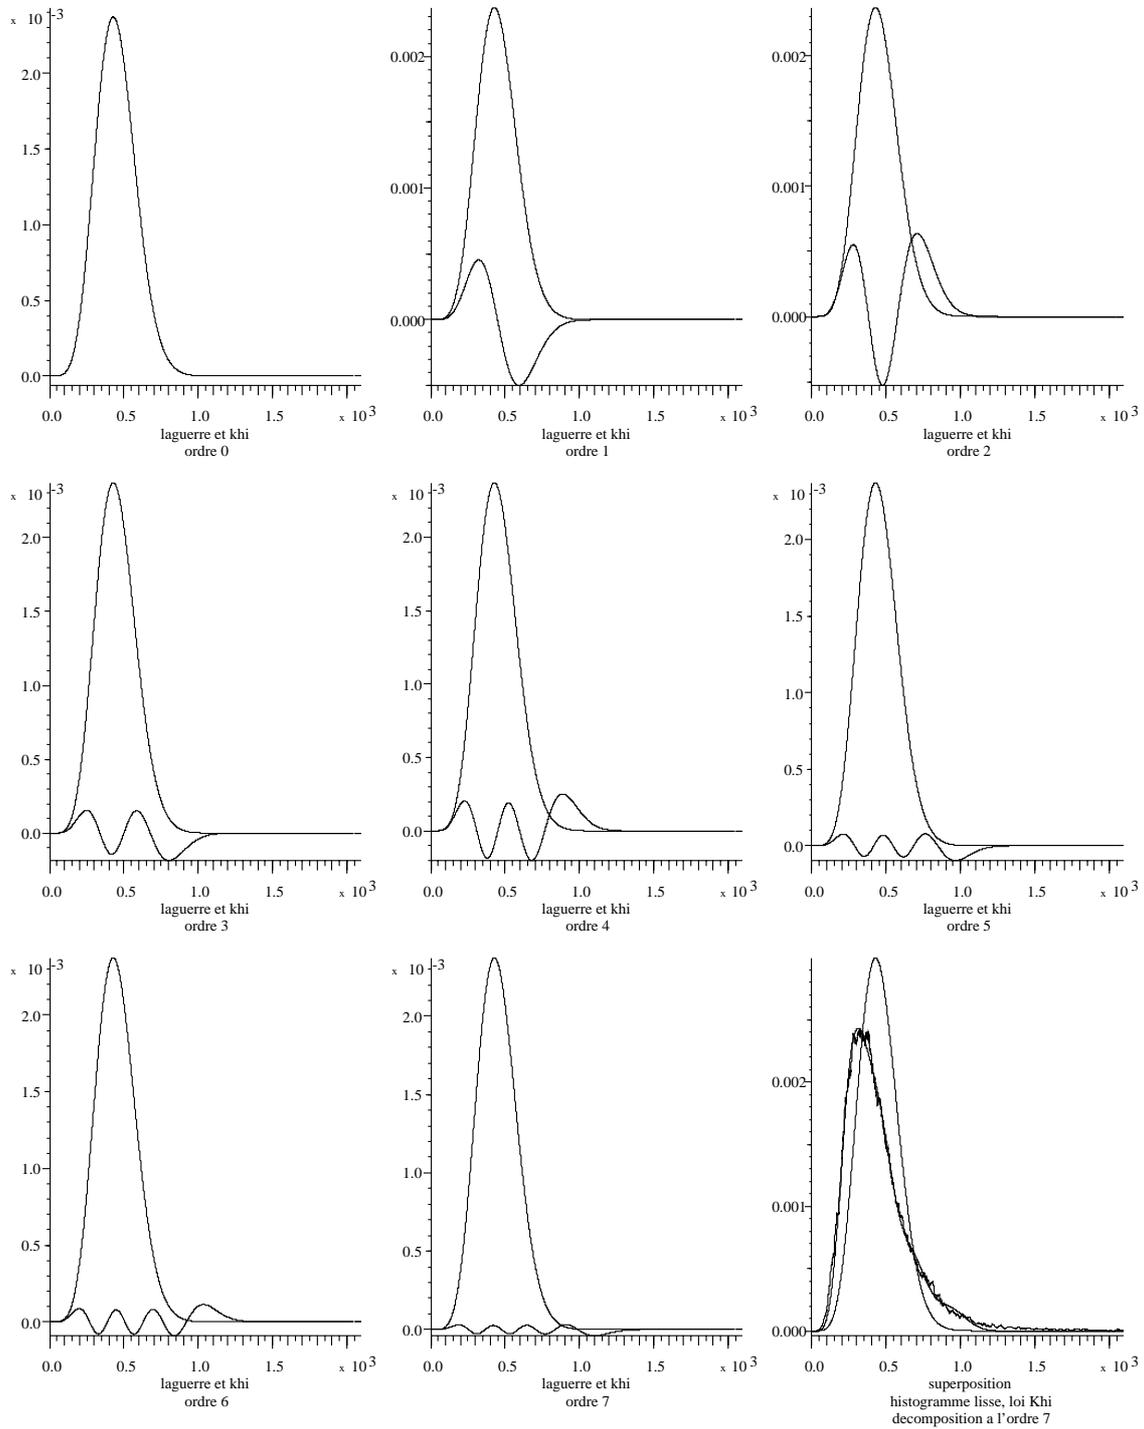


FIG. 7.5 – Superposition de la loi  $\chi$  et de la fonction  $\alpha_k F_k(x)$  pour différentes valeurs de  $k$  (de 0 à 7) sur l'image de zone urbaine et superposition de l'histogramme lissé, de la loi gamma généralisée (notée  $\chi$ ) et du résultat de la décomposition

$\alpha_0$	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	$\alpha_6$	$\alpha_7$
$7,91 \cdot 10^{-1}$	$7,94 \cdot 10^{-2}$	$2,93 \cdot 10^{-2}$	$1,84 \cdot 10^{-3}$	$4,36 \cdot 10^{-4}$	$2,5 \cdot 10^{-5}$	$4,0 \cdot 10^{-6}$	$< 10^{-7}$

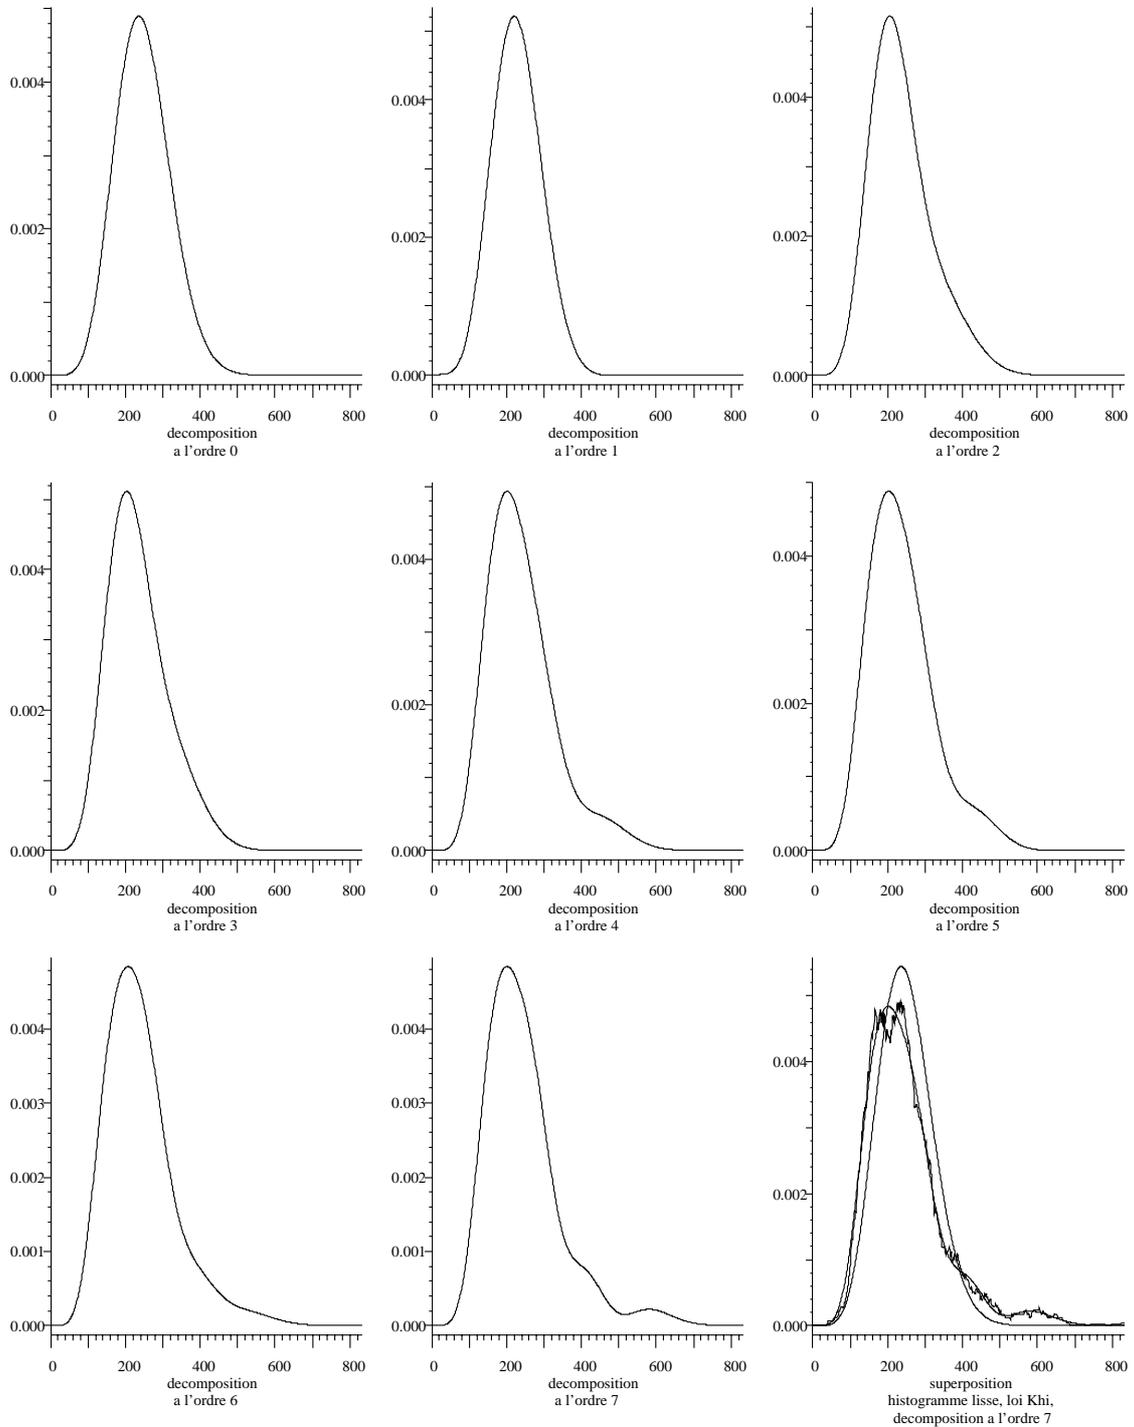


FIG. 7.6 –  $\sum_{k=0}^N \alpha_k F_k(x)$  pour différents ordres  $N$  (de 0 à 7) sur l'image de zone hétérogène et superposition de l'histogramme lissé, de la loi gamma généralisée (notée  $\chi$ ) et du résultat de la décomposition à l'ordre 7

$\alpha_0$	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	$\alpha_6$	$\alpha_7$
$8,99 \cdot 10^{-1}$	$7,04 \cdot 10^{-2}$	$1,72 \cdot 10^{-2}$	$5,25 \cdot 10^{-5}$	$2,46 \cdot 10^{-4}$	$1,1 \cdot 10^{-5}$	$1,8 \cdot 10^{-6}$	$-2,02 \cdot 10^{-7}$

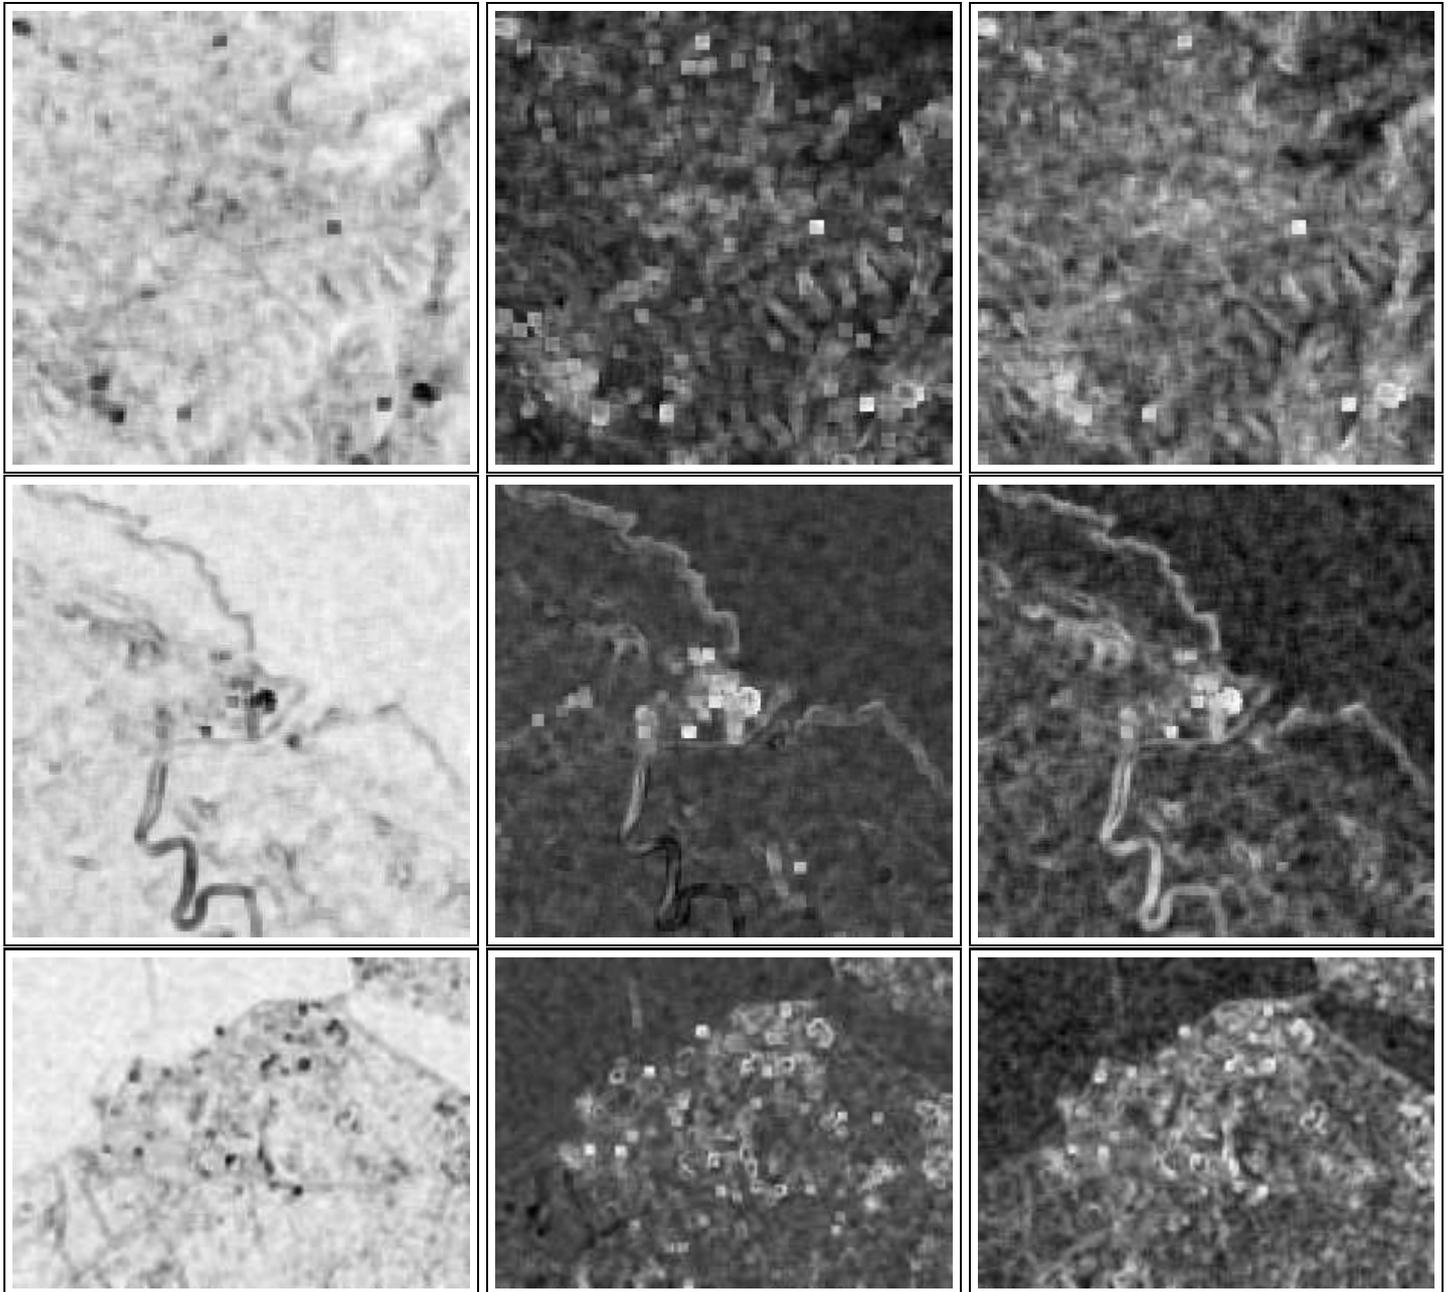


FIG. 7.7 – Images des coefficients de la décomposition de l'histogramme à l'aide des polynômes de Laguerre (dynamique ramenée à 256 entre le minimum et le maximum de l'image) sur Aix-en-Provence, Kourou et Flevoland (de haut en bas), avec, de gauche à droite,  $\alpha_0$ ,  $\alpha_1$ ,  $\alpha_2$  (images radar originales cf. A.5, A.6, A.2)

L'idée est d'imposer un modèle connu, en l'occurrence un modèle auto-régressif gaussien, au logarithme de l'image radar pour lequel le bruit est devenu additif. Frankot et Chelappa définissent ainsi un modèle auto-régressif multiplicatif (MAR) log-normal :

$$y(s) = \prod_{r \in N} y(s+r)^{\theta_r} \nu(s)$$

avec  $\nu(s)$  un bruit blanc log-normal,  $s$  l'indice d'un site, et  $N$  un voisinage définissant un modèle unilatéral en deux dimensions, donc inclus par exemple dans le demi-plan Nord-Ouest, l'origine non comprise. En définitive,  $y(s)$  suit un modèle MAR log-normal, si son logarithme  $x(s) = \ln y(s)$  suit un modèle gaussien auto-régressif :

$$x(s) = \sum_{r \in N} \theta_r x(s+r) + u(s) \text{ où } u(s) = \ln \nu(s)$$

Les différents paramètres intervenant dans ce modèle,  $\theta_r$ ,  $r \in N$  et l'écart-type du bruit blanc gaussien  $u$  noté  $\sigma_u$ , définissent la texture d'une région.

La loi log-normale a été proposée par de nombreux auteurs, que ce soit pour la scène [Ulab-80] [Lewi-83] [Nezr-92] ou pour l'amplitude rétrodiffusée [Laur-89], en particulier dans le cas où la variance de la scène est importante [Lewi-83]. Par ailleurs, testé sur plusieurs images radar réelles, le modèle MAR s'est révélé bien adapté [Fran-87].

L'estimation aux moindres carrés des paramètres du modèle se fait par la résolution des équations de Yule-Walker [Kash-83] [Cari-91]. Notons  $\theta$  le vecteur de paramètres  $\theta = \text{col}[\theta_r, r \in N]$ ,  $\hat{x}$  la moyenne empirique de  $x$ , et  $V(s) = \text{col}[x(s+r) - \hat{x}, r \in N]$ , alors l'estimation de  $\theta$  notée  $\hat{\theta}$  est donnée par :

$$\hat{\theta} = \left[ \sum_s V(s) V^t(s) \right]^{-1} \left[ \sum_s V(s) (x(s) - \hat{x}) \right]$$

en notant  $V^t$  le vecteur transposé de  $V$ . L'écart-type du bruit est obtenu alors par :

$$\sigma_u^2 = \frac{1}{M^2} \sum_s \left( x(s) - \hat{x} - \hat{\theta}^t V(s) \right)^2$$

Nous avons appliqué cette méthode aux images ERS-1 avec  $N = \{(0, -1), (-1, -1), (-1, 0)\}$  (i.e pixels Nord, Nord-Ouest, Ouest respectivement). Comme précédemment, nous illustrons la méthode sur des petites images tests. Le tableau 7.1 montre les paramètres du modèle MAR log-normal pour différentes régions. Les paramètres  $\theta_r$  ne semblent pas être significatifs quant à l'homogénéité de la texture. Par contre, l'écart-type du bruit  $\sigma_u$  augmente avec l'hétérogénéité de la scène. Des images de différentes textures ont également été simulées en utilisant les paramètres obtenus et en conservant la première ligne et la première colonne de l'image étudiée pour initialiser le processus (fig.7.8). La ressemblance des synthèses obtenues dépend du type de texture analysé ; dans le cas du chatolement totalement développé, l'aspect granuleux du speckle de la synthèse est sur écran visuellement différent de celle de l'image originale.

Tenant compte de ces résultats, nous avons calculé une image de l'écart-type du bruit  $\sigma_u$  sur les trois scènes. Un champ stationnaire étant une des hypothèses du modèle, nous avons réalisé le calcul des paramètres localement sur une fenêtre d'analyse centrée en chaque pixel.

TAB. 7.1 – Paramètres du modèle MAR log-normal

Zone test	$\theta_{(0,-1)}$	$\theta_{(-1,-1)}$	$\theta_{(-1,0)}$	$\sigma_u$
homogène	0.508	-0.195	0.422	0.248
homogène	0.585	-0.219	0.415	0.233
hétérogène	0.618	-0.242	0.538	0.321
hétérogène	0.380	-0.085	0.465	0.438
hétérogène	0.576	-0.285	0.627	0.364

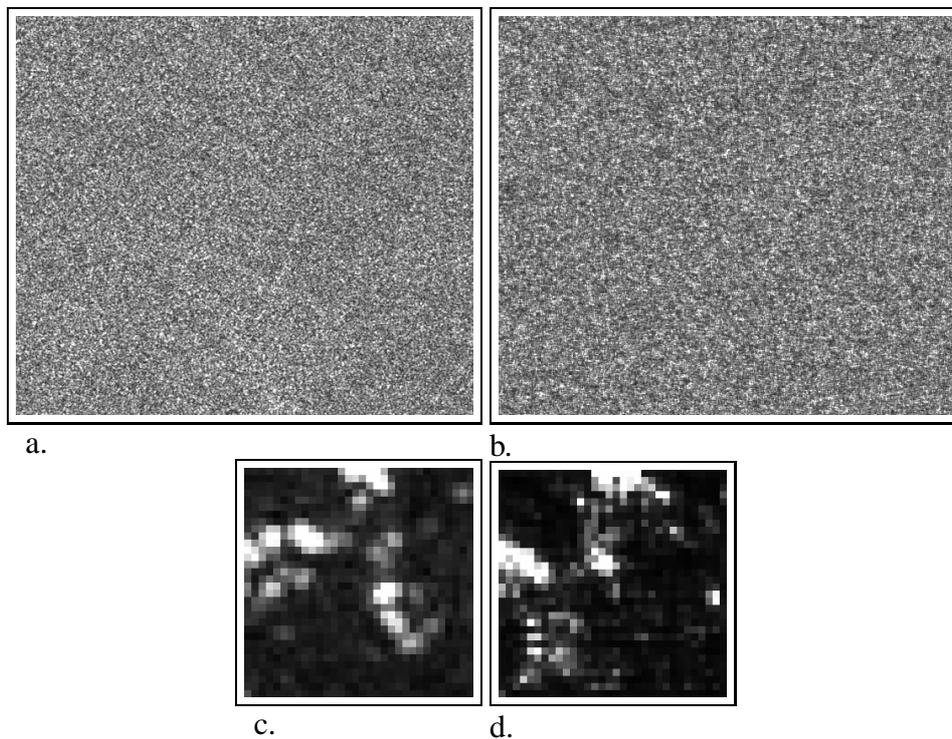


FIG. 7.8 – Simulations de textures utilisant les paramètres du modèle MAR sur une zone homogène et sur une zone hétérogène ; à gauche les images radar originales, à droite les simulations correspondantes

Par ailleurs, conformément aux remarques de [Fran-87], les résultats ont été améliorés par une dégradation de la résolution réalisée sous forme d'un moyennage par blocs  $4 \times 4$ . La taille de la fenêtre d'analyse est dans ce cas de  $9 \times 9$  pixels. Les résultats obtenus dans ces conditions sont montrés sur la figure 7.9. La dégradation de la résolution et le type de la méthode permettent de ne détecter que les homogénéités et les hétérogénéités de zones suffisamment grandes, et de ne pas répondre aux contours ou aux structures linéiques de l'image.

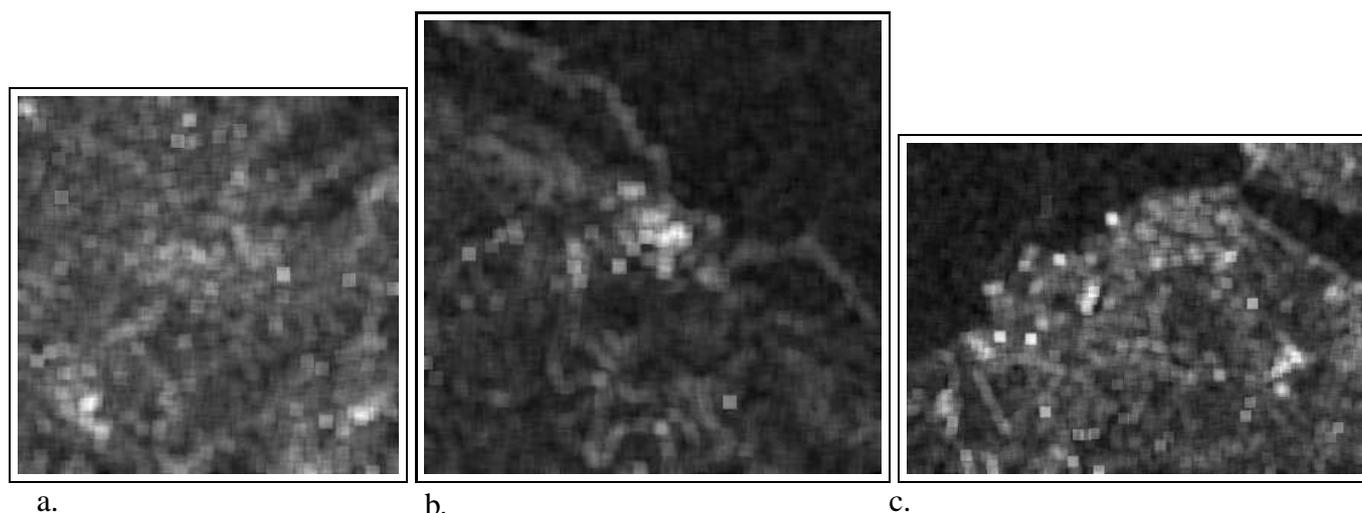


FIG. 7.9 – Images de l'écart-type du bruit du modèle MAR log-normal : a. Kourou (cf. §A.6), b. Aix-en-Provence (cf. §A.5), c. Flevoland (cf. §A.2)

#### 7.1.4 Comparaison des résultats des trois méthodes

Pour comparer les résultats obtenus, nous nous sommes fixés deux objectifs : la discrimination des zones très texturées (zones industrielles), et celle des zones très homogènes (mer, certains types de végétation).

Les trois méthodes ont été testées sur toute la base de données de l'annexe A, dans les conditions suivantes :

- calcul du rapport de la moyenne arithmétique sur la moyenne géométrique : il a été effectué sur l'image à la résolution originale avec une fenêtre  $11 \times 11$ , et sur l'image réduite en blocs  $4 \times 4$  avec une fenêtre  $9 \times 9$  ;
- décomposition de l'histogramme : seule l'image du coefficient  $\alpha_0$  a été considérée, l'histogramme étant calculé sur une fenêtre  $32 \times 32$  à la résolution originale, mais seulement un point sur huit en lignes et en colonnes étant traité ;
- modélisation MAR log-normale : le paramètre  $\sigma_u$  a été calculé sur une image dégradée  $4 \times 4$  pour une fenêtre  $9 \times 9$ .

La comparaison des résultats a été effectuée par simple seuillage du rapport des moyennes, des coefficients de la décomposition ou de l'écart-type du bruit du modèle MAR, à différentes valeurs sur toutes les images. La meilleure mise en évidence des zones très homogènes et très hétérogènes a été obtenue pour l'écart-type du modèle MAR.

En conclusion, ce modèle a donné les meilleurs résultats par rapport à l'objectif que nous nous étions fixé, et sur des images ERS-1. Il est probable qu'à une autre résolution et avec un objectif de classification totale de l'image, des résultats différents auraient été obtenus. De plus, nous nous sommes intéressés à la détection de zones de tailles relativement grandes, et non à la mise en évidence de structures locales (contours, lignes, points réflecteurs). Par conséquent, le fait de dégrader la résolution pour l'utilisation du modèle MAR nous a permis de distinguer ces régions du reste de la scène. Le rapport moyenne arithmétique sur moyenne géométrique, au contraire, est très sensible aux transitions entre régions

ou à des réflecteurs isolés, donnant des résultats bruités et ne permettant pas la discrimination des zones très hétérogènes des zones de transition entre régions différentes. Quant à la décomposition de l'histogramme à l'aide des polynômes de Laguerre, l'information nous a semblé difficilement exploitable en l'absence d'études plus approfondies à l'aide d'une base d'apprentissage.

### 7.1.5 Application à la détection des zones homogènes

Comme il a été mentionné dans le paragraphe précédent, la méthode retenue utilise l'écart-type du modèle multiplicatif auto-régressif local. En effet, la dégradation de la résolution liée à son utilisation a peu d'importance puisque nous cherchons à détecter des zones de grandes dimensions. De plus, un simple seuillage, suivi d'une fermeture pour régulariser les régions obtenues, donne des résultats satisfaisants. D'ailleurs, un seuil unique, correspondant à un écart-type du bruit inférieur à 0,16, suffit pour exploiter l'ensemble des images ERS-1. Notons qu'une technique par hystérésis aurait également pu être utilisée.

Plusieurs post-traitements sont ensuite effectués pour améliorer le résultat. Tout d'abord, seules sont conservées les composantes connexes de tailles suffisantes (supérieures à 300 pixels) et dont le coefficient de variation est inférieur à 0,33. Ce seuil est proche de la valeur théorique pour une zone de chatoiement totalement développé qui est de 0,3.

Par ailleurs, les régions détectées ont une forme assez approximative puisqu'elles proviennent d'une image dégradée par blocs  $4 \times 4$ , puis ramenée à la résolution initiale. Pour améliorer la forme des régions obtenues, une segmentation locale autour de chacune des régions a été effectuée sur l'image originale. La technique est celle décrite dans le chapitre 6, mais l'initialisation des moyennes des classes est légèrement différente. En effet, puisque nous cherchons à améliorer une région détectée, il faut qu'une des classes de la segmentation lui corresponde. Par conséquent, la moyenne de la région sert de moyenne à une des classes de la segmentation. D'autre part, la région initialement détectée n'est pas remise en question lors du recuit (elle est considérée comme fiable). Une autre solution pourrait consister à utiliser des contours actifs, en particulier ceux proposés par Germain et Réfrégier dans des contextes très texturés [Germ-97].

Cette étape permet de reconstruire en partie la région détectée. Pour améliorer les résultats, une fusion avec les régions qui lui sont adjacentes est envisagée. Nous avons testé deux critères de fusion. Le premier consiste à faire une détection de contours le long de la frontière entre deux régions, et à fusionner celles-ci si le pourcentage de contours significatifs est faible et si les moyennes des deux régions sont proches (un exemple est montré figure 7.10). Le second critère testé consiste à appliquer un test statistique, le test de Student, au logarithme de l'image [Cook-94]. En pratique, les régions obtenues par la segmentation sont de grandes tailles et le test de Student est rarement vérifié. En effet, plus le nombre d'échantillons disponibles augmente, plus les moyennes et les écarts-types des deux populations doivent être proches pour que le test de Student soit positif.

Dans la majorité des cas, nous nous sommes contentés d'utiliser le résultat de la segmentation sans effectuer l'opération de fusion qui s'est avérée insuffisante, exceptés les cas très simples comme celui de la figure 7.10.

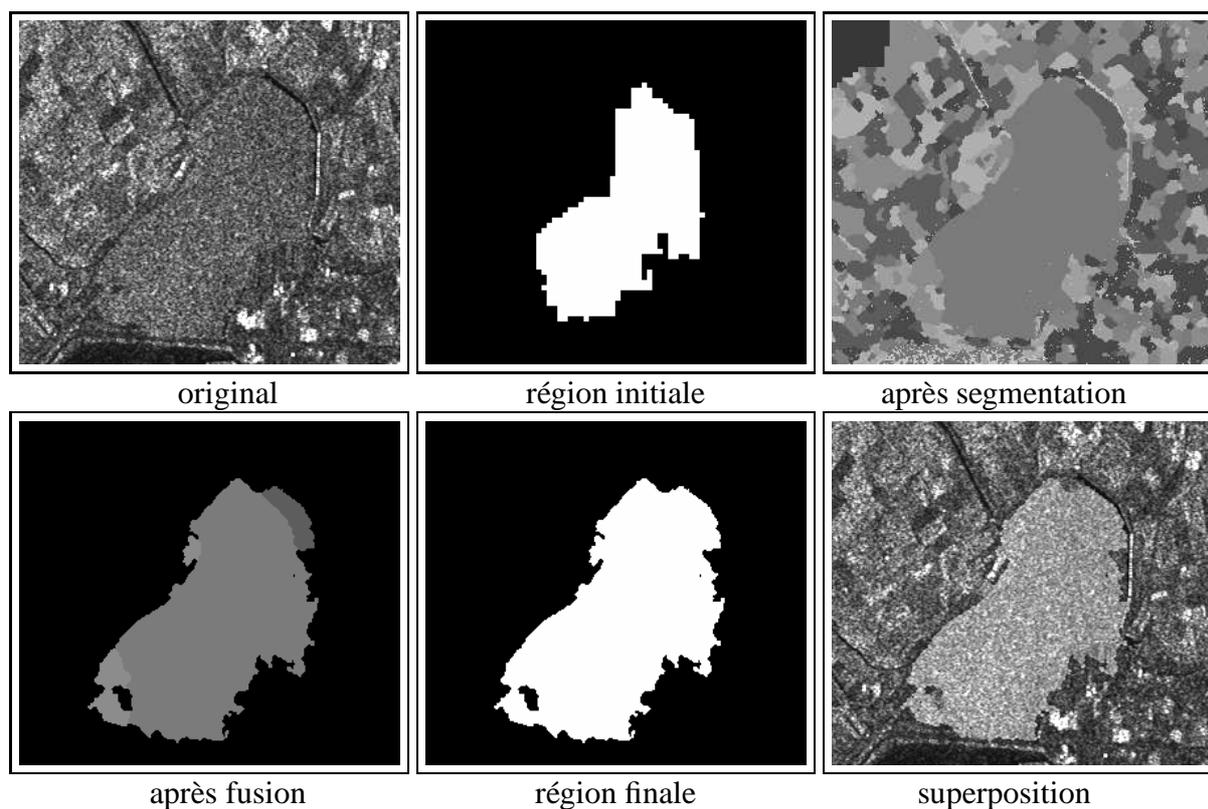


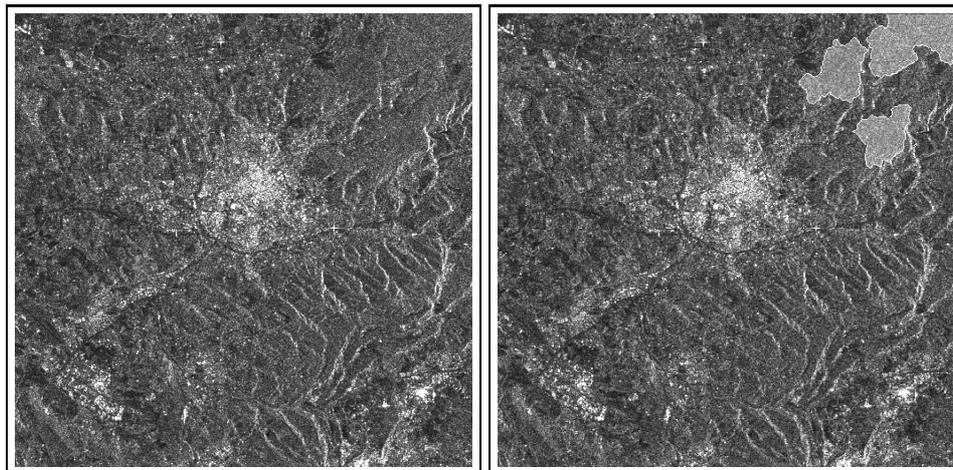
FIG. 7.10 – *Etapes de la méthode de repositionnement des frontières des régions homogènes détectées*

Les résultats de la figure 7.11 montrent les zones détectées par cette méthode. Tous les paramètres intervenant sont les mêmes pour toutes les images. Les zones visuellement homogènes sont effectivement détectées, que ce soient les zones de mer ou de végétation, mais les frontières restent approximatives malgré le repositionnement (empiètement sur le fleuve dans l'image de Kourou par exemple, ou éloignement de la côte pour la mer). En fait, des hétérogénéités radiométriques significatives au bord des côtes en sont les principales responsables, conjointement au fait que la forme initialement détectée n'est jamais remise en question.

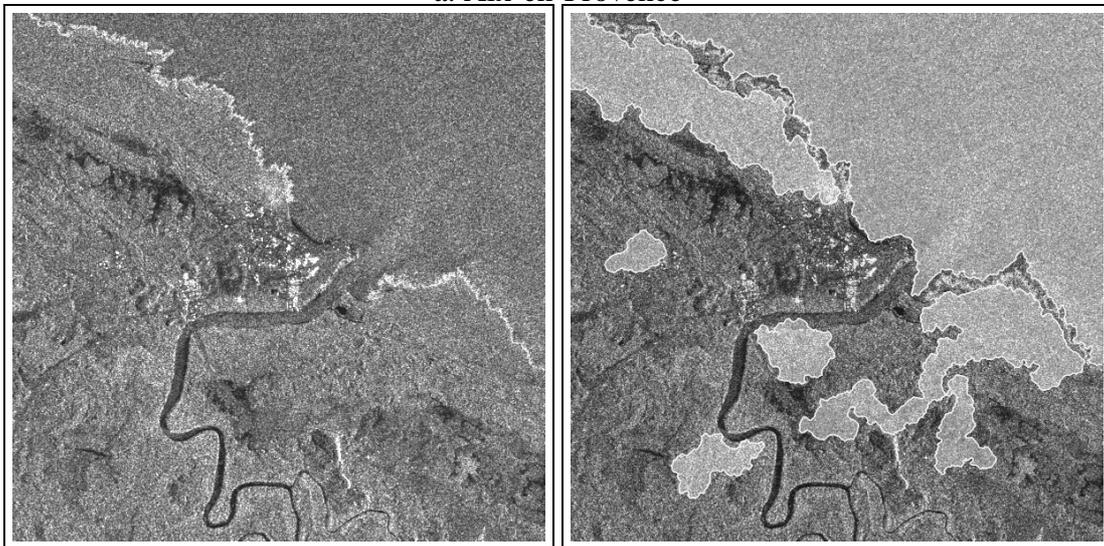
### 7.1.6 Application à la détection des zones industrielles

Il s'agit ici de détecter les régions très hétérogènes constituées de forts réflecteurs caractéristiques des zones industrielles. Là encore, un simple seuillage sur l'image des écart-types du modèle MAR permet d'obtenir approximativement la localisation de ces régions. Le seuil utilisé sur la valeur de l'écart-type est de 0,325.

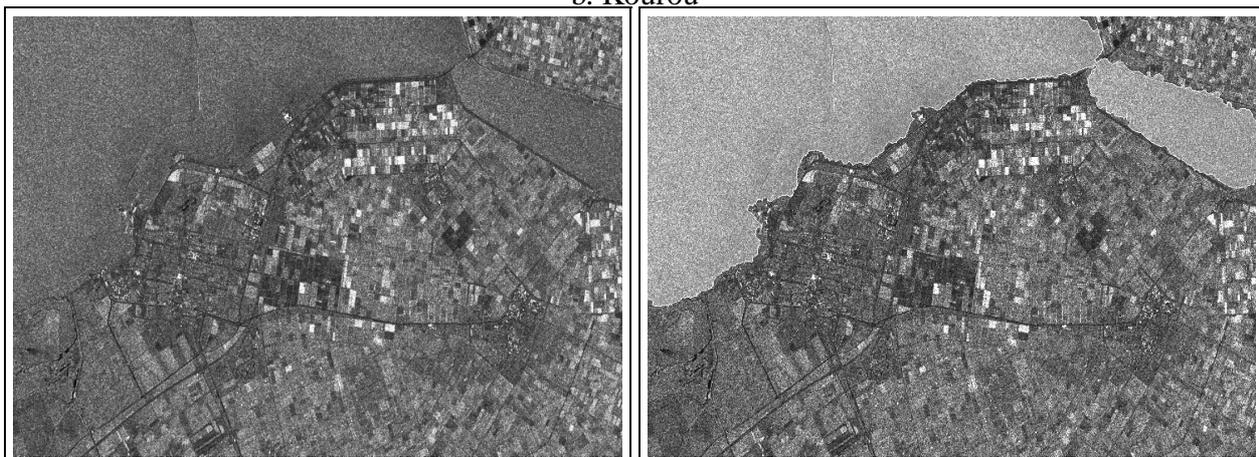
Comme précédemment, l'hétérogénéité des zones obtenues est vérifiée à l'aide du coefficient de variation. Nous avons considéré que celui-ci devait être supérieur à 0,6 pour qu'une région soit conservée (la valeur théorique en 3-vues pour une zone homogène est de 0,3).



a. Aix-en-Provence

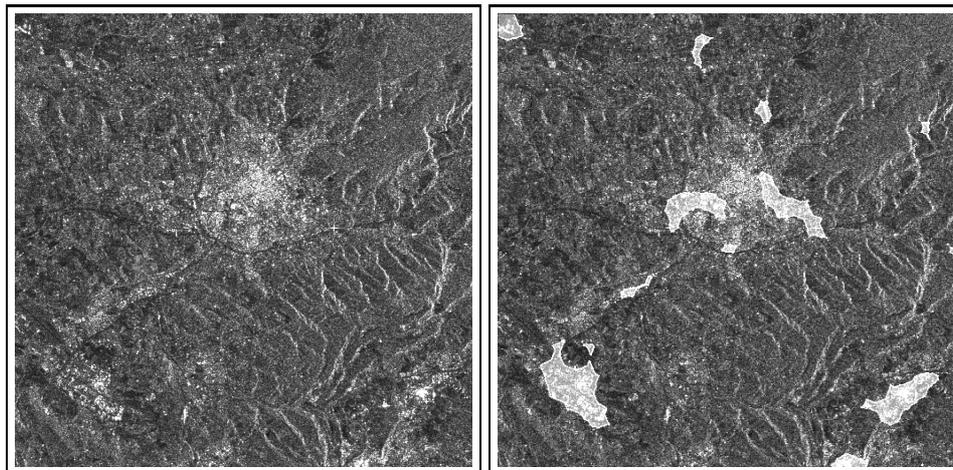


b. Kourou

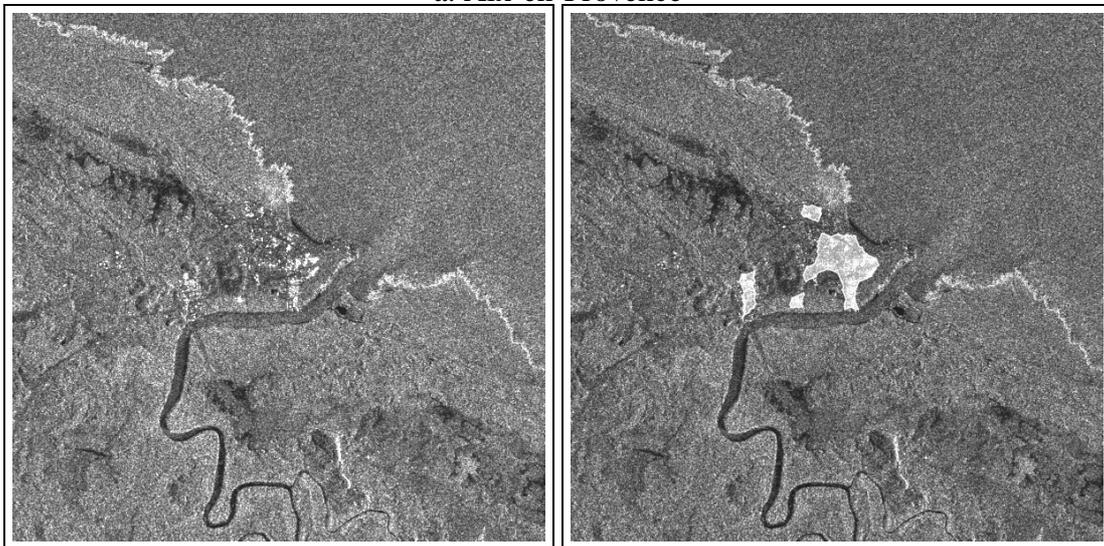


c. Flevoland

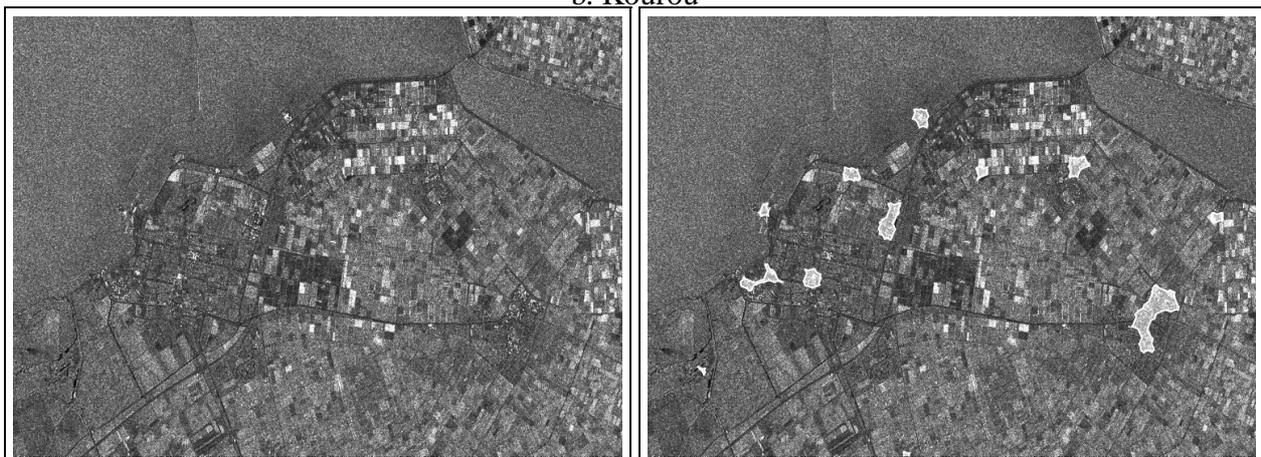
FIG. 7.11 – Détection des zones homogènes : à gauche, l'image originale (©ESA), à droite les régions détectées sont rehaussées radiométriquement (+60)



a. Aix-en-Provence



b. Kourou



c. Flevoland

FIG. 7.12 – Détection des zones hétérogènes : à gauche, l'image originale (©ESA), à droite les régions détectées sont rehaussées radiométriquement (+100)

Ensuite, pour obtenir le positionnement des forts réflecteurs, nous utilisons la méthode proposée par Gouinaud pour détecter les points brillants [Goui-96b]. Elle consiste à calculer la probabilité d'apparition d'une valeur radiométrique en supposant que le chatoiement est totalement développé. Mais la loi gamma généralisée, correspondant à un histogramme local, est calculée en utilisant non pas la moyenne locale mais la fréquence maximale de l'histogramme, peu affectée par la présence des forts réflecteurs en sur-nombre dans les zones industrielles. Ainsi, les pixels dont la probabilité d'apparition est inférieure à un seuil, et qui sont situés dans les régions détectées, sont classés comme appartenant au tissu urbain. Remarquons qu'il ne s'agit pas ici de trouver les forts réflecteurs présents dans l'image radar, mais simplement de détecter dans une zone déjà définie quels sont les pixels responsables de l'hétérogénéité détectée. Leur position est ensuite utilisée pour obtenir une forme approximative de la zone industrielle en effectuant une fermeture de très grand rayon (30 pixels par exemple).

Des résultats sont présentés pour différentes régions sur la figure 7.12. Comme on peut le constater sur celle-ci, cette méthode donne une indication sur la position des zones industrielles. En revanche, les zones urbaines très denses, comme le centre de la ville d'Aix-en-Provence ne sont pas détectées, quelque soit le discriminateur textural utilisé. D'autres part, nous pouvons remarquer que sur l'image du Flevoland, des fausses alarmes subsistent, notamment en frontière de champs très brillants.

## 7.2 Identification des zones urbaines

Nous présentons dans cette partie deux méthodes pour la détection des zones très hétérogènes correspondant au milieu urbain.

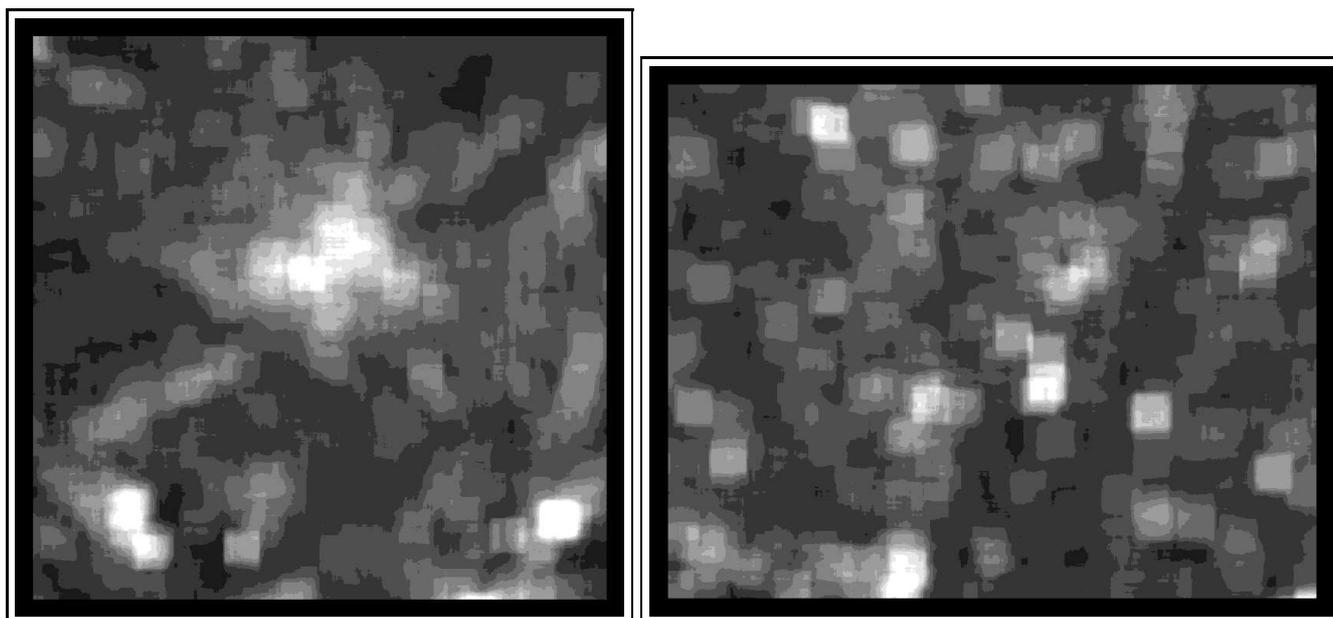
### 7.2.1 Analyse de la queue de l'histogramme

Nous reprenons ici une idée développée par C. Gouinaud pour la discrimination du milieu urbain sur les images radar [Goui-96] [Goui-96b]. L'objectif de la technique exposée est de quantifier la densité urbaine au voisinage de chaque pixel. Pour cela, l'histogramme est construit sur une fenêtre de taille  $60 \times 60$  et la queue de cet histogramme est analysée. En particulier, la valeur du seuil  $s$  à partir de laquelle le cumul des fréquences des fortes valeurs est supérieur à la fréquence maximale  $f_{\max}$  est déterminée, i.e :

$$\sum_{i=s}^{maxg} f_i > f_{\max}$$

où  $f_i$  est la fréquence du niveau radiométrique  $i$  et  $maxg$  le niveau de gris maximum sur l'image. En réalité, tous les seuils possibles ne sont pas testés, mais des seuils  $s(k)$  de la forme  $s(k) = \mu + k\sigma$  sont choisis. La moyenne  $\mu$  et l'écart-type  $\sigma$  intervenant dans cette expression sont calculés sur des zones de l'image qui sont relativement homogènes. Les valeurs de  $k$  obtenues en chaque pixel donnent alors une indication de la densité urbaine. Cet opérateur sera appelé l'opérateur "ffmax" dans la suite.

L'utilisation de l'indice  $k$  obtenu appelle quelques remarques. Cette technique permet de bien mettre en évidence les zones de forte radiométrie : urbain dense et zones industrielles pour lesquelles la concentration des échos forts est suffisante (fig.7.13a). En revanche, les champs de très fortes radiométries qui sont imagés dans certaines conditions de sols et d'humidité, et qui répondent aux critères de l'opérateur, seront également détectés (fig. 7.13b). Des perturbations plus faibles peuvent être occasionnées par les lignes brillantes qui apparaissent dans les zones de relief (fig.7.13a). Cet effet est limité par l'utilisation d'une fenêtre d'apprentissage relativement large et carrée qui est peu sensible à l'influence d'une structure très linéaire.



a. résultat pour Aix-en-Provence (cf. annexe A.5)

b. résultat pour Lorient (cf. annexe A.3)

FIG. 7.13 – Opérateur "ffmax" pour 10 valeurs de  $k$  (plus  $k$  augmente, plus la queue de l'histogramme a de l'importance, relativement à la fréquence maximale)

### 7.2.2 Analyse de la densité de très forts réflecteurs

Les zones industrielles sur les images radar sont caractérisées par une forte concentration de réflexions spéculaires dues aux réponses des bâtiments dans certaines orientations. Nous proposons ici une méthode simple de détection des zones très hétérogènes à cause de la présence de forts réflecteurs.

A partir de la sélection des points spéculaires de l'image expliquée ci-dessous le calcul des régions de Voronoï [Prep-88] permet une extraction rapide des zones où ces points sont les plus denses. En effet, la taille des régions de Voronoï diminue proportionnellement à l'augmentation de la concentration des points brillants. Nous ne conservons donc que les petites régions que nous regroupons ensuite en zones par une simple dilatation. Finalement, seules les zones de tailles suffisantes (donc contenant un nombre de forts réflecteurs suffisant) correspondent à des zones industrielles.

La détection des forts réflecteurs se fait en utilisant le résultat de la segmentation automatique de l'image. Les pixels étiquetés dans les classes de plus forte radiométrie sont considérés comme candidats et les régions suffisamment petites donnent les réflecteurs spéculaires. Le diagramme (fig.7.14) résume l'enchaînement des différentes étapes qui sont également illustrées sur l'image d'Aix en Provence (fig.7.15).

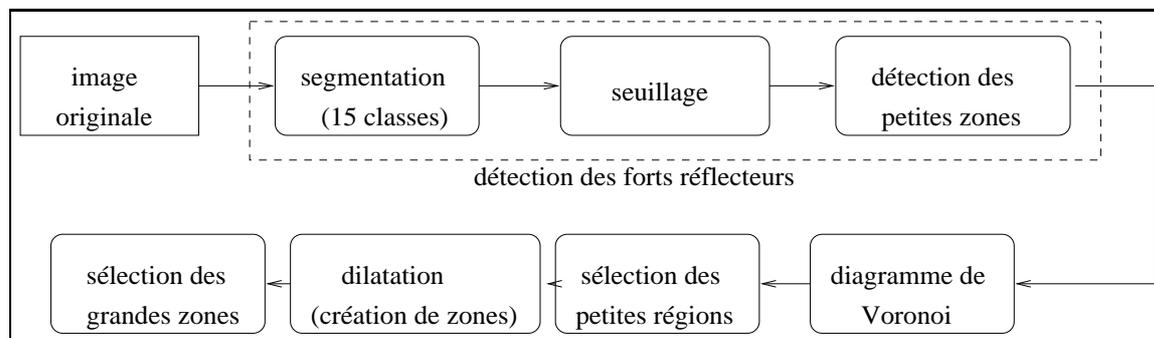


FIG. 7.14 – Diagramme des opérations pour la détection des zones industrielles à forte densité de forts réflecteurs

Cette méthode très simple a donné de bons résultats avec un jeu de paramètres fixé sur les images de notre base de données. Elle présente l'intérêt de pas répondre aux champs clairs ni au relief pour lesquels la densité de forts réflecteurs est insuffisante. En revanche, elle ne détectera pas l'urbain très dense (comme le centre d'Aix-en-Provence). Nous verrons dans la troisième partie comment les informations apportées par ce détecteur et l'opérateur "ffmax" précédent permettront une détection satisfaisante et fiable des zones urbaines.

### 7.3 Conclusion et perspectives

Nous nous sommes intéressés dans ce chapitre aux discriminateurs texturaux adaptés aux images radar et plus particulièrement à la détection des zones très homogènes (mer ou forêt) et très hétérogènes (milieu industriel). Si les outils présentés permettent une bonne discrimination de ces textures "extrêmes" qui nous intéressent dans cette thèse, une discrimination plus fine devra faire appel à des outils plus spécifiques [Marz-96]. A titre de perspective, nous pensons que l'utilisation des paramètres d'un champ markovien dont l'image serait supposée être une réalisation devrait également apporter des résultats intéressants. Étudiée par Descombes [Desc-93], cette méthode a été expérimentée avec succès pour la discrimination du milieu urbain sur SPOT. Son utilisation sur les images radar nécessite cependant une étude rigoureuse car l'hypothèse d'un champ markovien gaussien n'est pas forcément la plus adaptée (les résultats obtenus dans ce cas sont comparables à ceux de l'écart-type du modèle auto-régressif). Un autre choix, notamment en utilisant les statistiques des images radar, nécessite un examen des conditions d'application de la méthode du gradient énergétique proposée par cet auteur. Par ailleurs, eu égard à la très bonne approximation de l'histogramme que permet la combinaison des polynômes de Laguerre, nous pensons que cette technique mériterait d'être approfondie dans un objectif de classification à l'aide d'une base de données test.

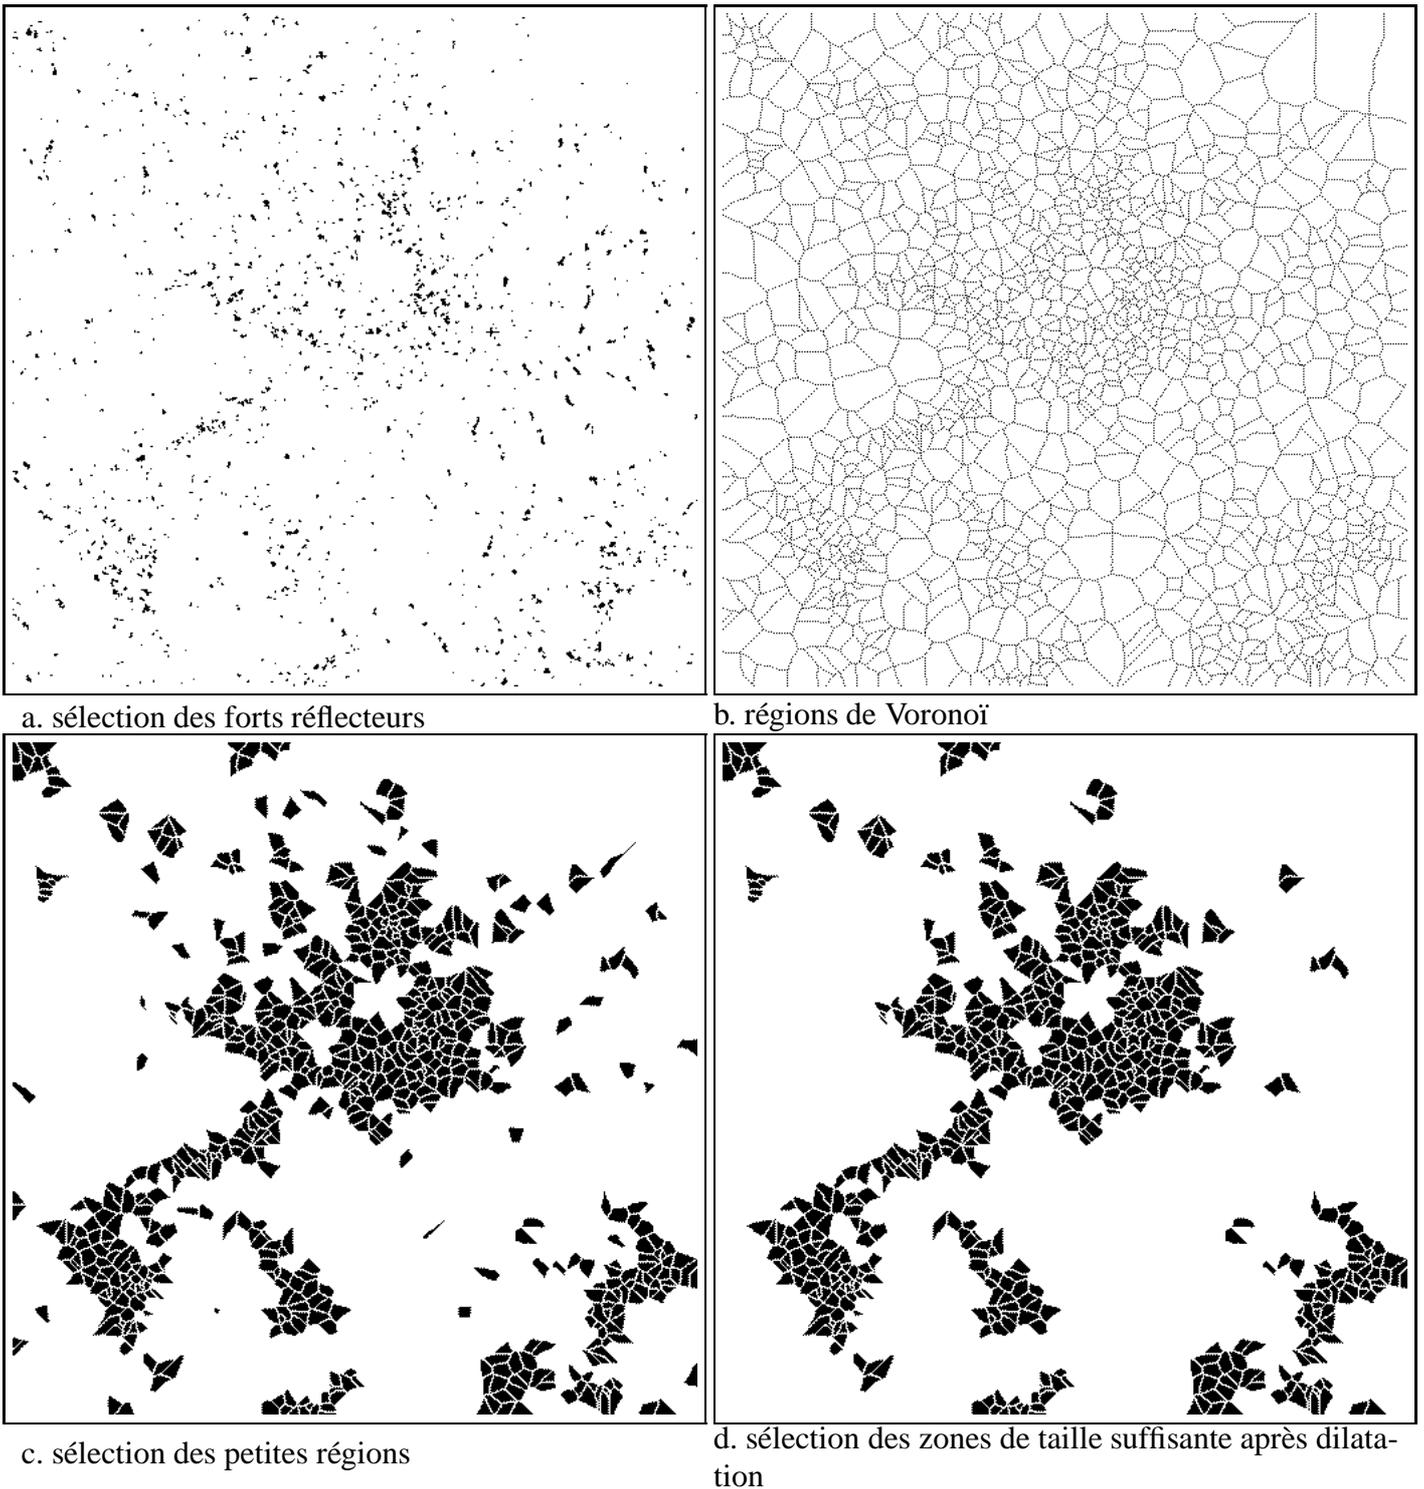


FIG. 7.15 – *Étapes intermédiaires de la détection des zones avec une forte densité de points brillants sur l'image d'Aix-en-Provence (image radar originale cf. annexe A.5)*

Notre contribution se limite dans ce chapitre à la généralisation au cas multi-vues de la décomposition de l'histogramme à l'aide des polynômes de Laguerre, et à la proposi-

tion d'utiliser un diagramme de Voronoï sur des forts réflecteurs pour détecter les zones urbaines. Néanmoins, l'implantation des différents discriminateurs texturaux et leur comparaison étaient indispensable pour justifier le choix de l'écart-type du modèle lognormal auto-régressif en tant que mesure d'homogénéité. Cet outil et les deux méthodes plus spécifiquement dédiées à l'analyse du milieu urbain, joueront, en venant s'ajouter aux autres opérateurs déjà présentés, un rôle essentiel dans le schéma d'interprétation final qui sera proposé.

## **Troisième partie**

### **Interprétation de la scène**



## Chapitre 8

# Fusion des informations par la théorie des croyances

*Nous abordons dans ce chapitre le problème de l'interprétation globale des images. Notre objectif est de réunir tous les éléments de la planimétrie dans une représentation aussi riche que possible de la scène. Après un rappel des méthodes existantes, nous proposons d'utiliser le cadre de la théorie des croyances pour combiner les diverses informations collectées lors des étapes de détection. Ainsi, nous définissons les fonctions de masses associées à chacun des détecteurs présentés dans les chapitres précédents. Celles-ci s'appuient sur une modélisation supervisée du fonctionnement des opérateurs. La fusion est ensuite effectuée par la somme orthogonale de Dempster - Shafer non normalisée, ce qui nous permet d'introduire naturellement une classe de rejet. Finalement, l'interprétation est effectuée par une étape de régularisation markovienne sur le graphe d'adjacence des régions. Les résultats obtenus sur les images de notre base de données sont ensuite analysés pour mesurer les performances et les limites de la méthode.*

### 8.1 Introduction

Le but ultime des différents outils développés jusqu'à maintenant est de permettre l'interprétation complète de l'image radar. Une première solution pourrait consister en l'extraction des différentes classes d'intérêt séparément et en leur superposition sur un résultat final moyennant des règles de priorité en cas de conflit. La figure 8.1 rappelle le principe de ce schéma avec les opérateurs développés. Une telle solution n'est évidemment pas satisfaisante dans le sens où nous n'exploitons ni la redondance ni la complémentarité des classes considérées pour prendre les décisions. Ce schéma correspondrait à un schéma décentralisé [Bloc-94] qui ne tient pas compte des relations entre opérateurs. Avant de détailler la méthode que nous proposons d'appliquer dans le cas de l'interprétation monosource d'une image satellitaire radar, nous rappelons les méthodes existantes pour l'interprétation globale des images.

Objectif final du traitement d'images, l'interprétation globale de la scène a donné lieu à de très nombreuses recherches qui font intervenir notamment le domaine de l'intelligence

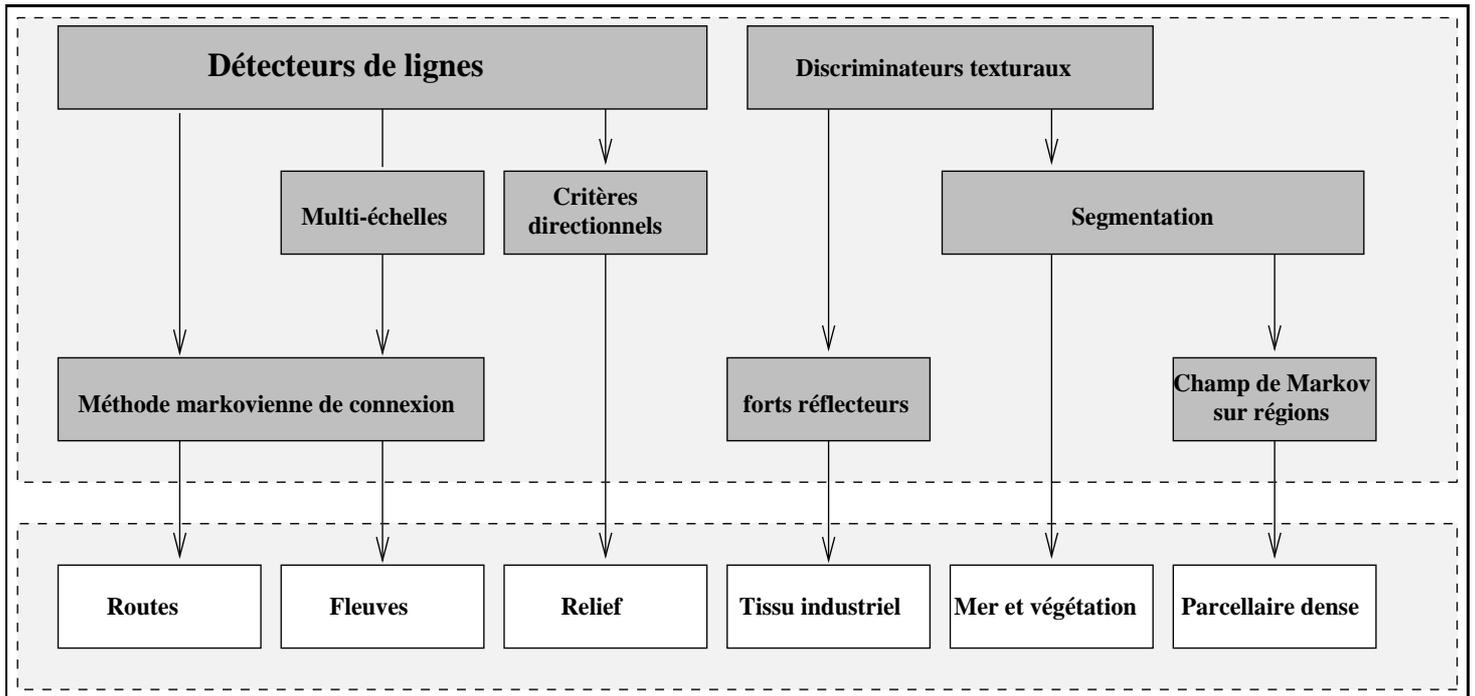


FIG. 8.1 – Outils développés et méthodes de détection des objets sémantiques

artificielle. Le problème traité est souvent lié à une application précise (imagerie médicale, aérienne, satellitaire, ...) dans des conditions particulières (mono-source, multi-sources) et les méthodes proposées sont parfois difficilement transposables à d'autres domaines, ce qui rend difficile une classification. Nous avons néanmoins choisi de distinguer trois familles de méthodes : les systèmes à base de règles, les méthodes fondées sur des graphes et les méthodes de fusion numérique.

### 8.1.1 Les systèmes à base de règles

D'une façon générale, ces systèmes s'articulent en trois éléments principaux : une base de faits, une base de règles et un moteur d'inférence. Un cadre souvent utilisé est celui du tableau noir [Haye-83] dont l'architecture permet le recensement de toutes les données acquises par le système dans une base de données globale mise à jour après l'application de chaque agent. Citons quelques-uns des systèmes experts développés en traitement d'images aériennes et satellitaires :

- ACRONYM [Broo-81] [Binf-82] pour la reconnaissance d'avions dans les images aériennes d'aéroports ;
- ICARE [Desa-90] [Zahz-92] pour l'interprétation multi-sources d'images satellitaires (images Landsat MSS avec cartes et Modèle Numérique de Terrain permettant d'accéder à la pente) ; une des applications décrites est la classification des différents types de végétation [Zahz-92] ;
- MESSIE [Garn-88] [Garn-89] [Clem-93] [Houz-93] pour l'interprétation multi-sources d'images satellitaires ou aériennes (images SPOT, SAR, cartes,...) ; une application pour la

détection d'éléments cartographiques utilisant conjointement des images optiques et radar est décrite ; nous retiendrons en particulier la démarche générale, qui consiste à hiérarchiser la recherche des informations en fonction de la facilité de la détection (notamment avec la classification des objets [Houz-93], et la formalisation des différents processus de fusion [Houz-94]) ;

- SIGMA [Mats-86] pour l'interprétation d'images aériennes en milieu péri-urbain ;
- SPAM [McKe-85] pour l'interprétation des images aériennes d'aéroports ; ce système présente l'avantage d'être très général, et une interface interactive permet d'introduire efficacement de nouvelles règles dans la base de connaissances [McKe-89] (apprentissage de la règle par des exemples, mesure de l'impact de la règle sur le processus d'interprétation, etc.) ;
- VISIONS [Hans-88] pour l'interprétation d'images d'extérieur.

Ces systèmes, malgré leur aptitude à modéliser les raisonnements déductifs sous-jacents que nous sommes amenés à utiliser pour interpréter une image, présentent plusieurs inconvénients. Tout d'abord le recensement des règles à introduire est relativement lourd, même si des solutions existent pour le faciliter (système interactif convivial [McKe-85], apprentissage par réseaux de neurones [Zahz-92], classification générale [Houz-93]). Ensuite, il est difficile d'envisager toutes les situations exceptionnelles possibles. Prenons l'exemple de l'image ERS-1 des Flevoland : l'immense pont liant les deux polders contrarie la règle pourtant naturelle "il n'y a pas de routes sur la mer". Finalement, la lourdeur de tels systèmes se justifie assez peu dans notre contexte. En effet, les règles sont nécessairement limitées par le faible nombre d'objets que nous sommes capables d'interpréter sur les images radar.

### 8.1.2 Les méthodes fondées sur des graphes

Ces méthodes consistent à représenter la scène sous forme d'un graphe relationnel généralement attribué (GRA). Nous allons distinguer deux familles de méthodes utilisant une représentation sous forme de graphe : celles pour lesquelles il existe un modèle de la scène à interpréter (donné par exemple par une carte ou un atlas, ou même par une autre image considérée comme modèle), et celles où il n'en existe pas.

- **Connaissance d'un modèle de la scène :** le problème rejoint alors les problèmes de mise en correspondance et de recalage. Ayant construit les graphes représentant la scène et le modèle, on cherche alors le "meilleur" appariement entre ces deux graphes (au sens d'un critère donné). Généralement, une mesure de similarité entre graphes est définie et minimisée. Le graphe de la scène étant bien souvent bruité et celui du modèle parfois incomplet, c'est en réalité un isomorphisme entre sous-graphes qui est recherché. L'insertion et la suppression de nœuds d'un graphe peut être prise en compte en définissant le coût de chaque distorsion élémentaire. Les algorithmes utilisés s'appuient sur la programmation dynamique [Eshe-86], la recherche d'une clique maximale [Hora-89], la relaxation d'étiquettes [Faug-81] [Chri-95] [Finc-97], ou des approches plus heuristiques [Fan-89]. Plus récemment, l'emploi de techniques markoviennes a apporté des solutions prometteuses (pour la reconnaissance automatique des sillons corticaux [Mang-95a], et pour l'interprétation d'une image aérienne à l'aide d'une carte [Mois-96] [Cass-97]).

- **Absence de modèle :** c'est le cas dans lequel nous nous situons pour l'instant. Les graphes construits sont souvent de simples graphes d'adjacence définis à partir des régions d'une segmentation initiale. L'interprétation de la scène se ramène alors à un étiquetage des régions tenant compte de contraintes d'adjacence [Tene-77]. Le cadre markovien est alors particulièrement approprié lorsque les connaissances à introduire sont locales [Kim-93] [Kim-95] [Gera-95]. Une solution au difficile problème de l'estimation des paramètres, notamment pour le terme contextuel du champ, consiste à utiliser des réseaux de neurones [Kim-93]. De plus, segmentation et interprétation peuvent être réalisées simultanément en définissant un champ de Markov à deux niveaux (avec deux ensembles d'étiquettes, un pour la segmentation et un pour l'interprétation), ce qui permet aussi de s'affranchir de la qualité de la segmentation initiale<sup>1</sup> [Kim-95].

Nous reprendrons l'idée d'appliquer une méthode markovienne sur un graphe d'adjacence de régions pour régulariser le résultat obtenu par la théorie des croyances (cf. §8.4).

### 8.1.3 Les méthodes de fusion numérique

De nombreuses méthodes d'analyse de scène reposent sur la fusion numérique des informations délivrées par plusieurs sources ou issues de plusieurs opérateurs [Bloc-94]. Plusieurs cadres théoriques peuvent être utilisés [Dubo-88] [Bloc-97]. Le plus ancien et donc le plus courant est celui des probabilités [Lee-87] [Chau-95], mais la difficulté à prendre en compte l'imprécision au même titre que l'incertitude en limite les performances dans un grand nombre de situations. Pour pallier cette insuffisance et bien tenir compte de ces deux notions antagonistes que sont l'imprécision et l'incertitude<sup>2</sup>, d'autres théories ont été élaborées : les ensembles flous [Zade-65] [Zade-68] [Chau-95], la théorie des possibilités [Zade-78] [Dubo-94], et la théorie des croyances [Shaf-76]. Ces formalismes, et notamment la théorie des croyances, ont été utilisés pour de multiples applications aussi bien en imagerie satellitaire [Lee-87] [Zahz-92] [Kim-95] [LeHe-96] qu'en imagerie médicale [Chen-93] [Bloc-96b]. La fusion peut se faire au niveau des pixels comme au niveau de primitives plus élaborées (régions issues d'une segmentation par exemple [Cley-91]).

Notons que les techniques de fusion numérique sont intégrées dans la plupart des systèmes experts ou des systèmes à base de graphes [Andr-88] [Hans-88] [Mang-95a] [Mois-96].

### 8.1.4 Démarche proposée

Nous proposons dans ce chapitre une méthode hybride pour l'interprétation des images radar, dont nous donnons dans ce paragraphe les différentes étapes. Le problème que nous cherchons à résoudre est donc celui de la classification de l'image en  $N$  classes sémantiques notées  $C_i$  connaissant le résultat de  $K$  opérateurs  $O_j$ . Les classes  $C_i$  choisies dans notre application (écrites en italique dans la suite) et les opérateurs  $O_j$  utilisés sont indiqués dans le tableau 8.1 (les opérateurs seront définis précisément dans les sections suivantes). Bien que ces opérateurs soient souvent dédiés à l'extraction d'un objet spécifique de la scène,

1. Il faut néanmoins commencer le processus avec une sur-segmentation car seuls différents rassemblements de régions sont envisagés.

2. En effet, plus une information est précise, moins elle est certaine le plus souvent [Dubo-82].

ils apportent également des informations sur d'autres classes  $C_i$  : soit parce que les informations délivrées sont partiellement redondantes (par exemple dans notre cas la distinction entre l'urbain dense et les zones plus industrielles peut être imprécise), soit parce que les informations concernant une classe renseignent sur les autres (si une région de l'image est détectée comme particulièrement homogène, elle ne doit contenir a priori ni de structures linéaires fines, ni d'amas d'échos forts).

Notre objectif est donc de fusionner au mieux les réponses des opérateurs définis pour obtenir une cartographie de l'image en classes sémantiques. Dans notre cas, une grande partie de l'image radar n'est pas classifiable sans information extérieure (carte, image SPOT par exemple), et nous ne pouvons donc pas définir des classes qui soient exhaustives. Nous considérerons donc une classe de rejet  $C_o$ .

Parmi les contraintes pratiques que nous nous fixons, nous cherchons à développer une méthode modulable qui soit capable d'intégrer facilement l'ajout d'un nouvel opérateur ou d'une nouvelle classe. Pour que l'ajout d'une nouvelle source d'informations soit facilement pris en compte et que l'ordre de combinaison des opérateurs n'ait pas d'importance, il faut que la fusion entre opérateurs soit associative et commutative.

TAB. 8.1 – *Opérateurs et classes considérées dans l'application. La distinction entre la classe ville qui correspond à de l'urbain dense et la classe industriel qui correspond plutôt à des zones industrielles est sémantiquement imprécise et répond en réalité à l'apparence différente de ces deux classes sur les images radar (zone très claire homogène pour l'urbain très dense et zone avec de nombreux échos forts pour les zones urbaines moins denses).*

Opérateurs ( $K = 6$ )	Classes ( $N = 7 +$ classe de rejet)
opérateur "lignes brillantes"	<i>relief</i>
opérateur "routes"	<i>route</i>
opérateur "fleuves"	<i>fleuve</i>
opérateur "échos forts"	<i>homogène = mer <math>\cup</math> forêt</i>
opérateur "ffmax"	<i>ville</i>
opérateur " $\sigma_{MAR}$ "	<i>industriel</i>
	<i>champ clair</i>

Trois choix déterminants ont été faits pour réaliser l'interprétation de l'image : tout d'abord, le choix des primitives sur lesquelles la réaliser, ensuite le choix de la méthode de fusion proprement dite, et finalement le choix d'un critère de décision.

- **Choix des primitives sur lesquelles réaliser l'interprétation :** dans le cas des images satellitaires de grandes tailles, la fusion des informations pixel par pixel est coûteuse et souvent inutile. En effet, la précision des opérateurs est généralement trop médiocre pour justifier une méthode travaillant au niveau des pixels. C'est particulièrement le cas lorsque des opérateurs s'appuyant sur les statistiques calculées sur des fenêtres mobiles sont utilisées. Par exemple, l'écart-type du modèle auto-régressif est calculé sur une image moyennée  $4 \times 4$  et l'outil "ffmax" travaille sur des fenêtres de  $40 \times 40$  pixels. Nous proposons donc de réaliser la fusion non pas au niveau des pixels, mais au niveau de régions définies par exemple à partir d'une sur-segmentation.

- **Fusion :** nous avons énuméré dans l'introduction les méthodes existant pour résoudre

le problème de la fusion d'informations. Les systèmes experts et les méthodes à base de graphes nous semblent peu appropriés pour l'interprétation mono-source d'images satellitaires, en raison de leur lourdeur et du niveau d'interprétation trop élevé où elles se situent. En effet, nous ne considérons pas nos opérateurs comme des agents, et plutôt que de gérer des conflits entre eux comme dans les systèmes à base de règles, nous essayons de les prévenir en modélisant leur comportement. Quant aux méthodes à base de graphes, elles nous paraissent adaptées à une représentation réellement haut niveau de la scène qui nous sera accessible justement après la classification sémantique. Nous avons donc opté pour une méthode de fusion numérique dans le cadre de la théorie des croyances. Nous montrerons que sa grande souplesse pour prendre en compte l'imprécision et l'ignorance comparativement aux probabilités en fait un outil très adapté à la fusion des opérateurs. En outre, nous verrons qu'elle permet d'introduire naturellement la classe de rejet  $C_o$  lors de leur combinaison.

• **Décision** : l'étape de fusion précédente ne fait pas intervenir de relations contextuelles et le résultat obtenu après la fusion est un résultat dans lequel peuvent subsister des ambiguïtés lorsque les informations concernant l'appartenance d'une région sont insuffisantes. Nous proposons donc d'introduire dans l'étape de décision un critère de régularisation utilisant le contexte de chaque région pour lever ces ambiguïtés. Pour ce faire, un graphe d'adjacence est construit sur lequel un étiquetage markovien est effectué.

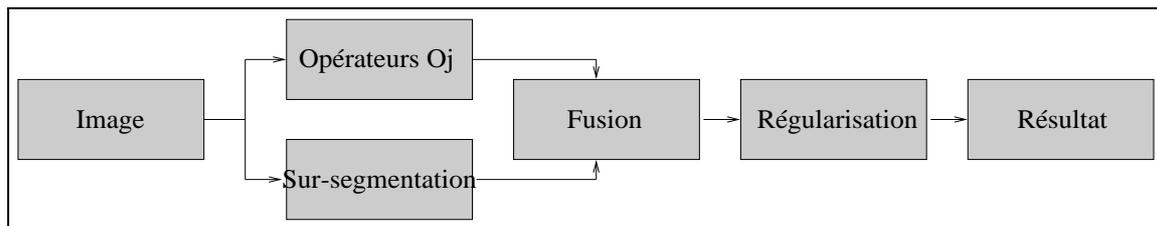


FIG. 8.2 – *Étapes de la méthode proposée*

La figure 8.2 résume les différentes étapes de la méthode proposée. Les sections suivantes font un rappel sur la théorie des croyances, puis présentent son application au cas de la classification mono-source d'une image satellitaire radar, ainsi que l'étape de régularisation markovienne. Finalement, les résultats obtenus par notre méthode sur des images satellitaires radar de différents capteurs sont analysés.

## 8.2 Rappels sur la théorie des croyances

La théorie des croyances ou "evidence theory" a été introduite par Dempster [Demp-68] et Shafer [Shaf-76]. Contrairement à l'inférence bayésienne, elle permet de prendre en compte l'ignorance, le manque d'information, sur un problème à traiter en considérant non seulement des hypothèses de départ mais aussi toutes les disjonctions de ces hypothèses. Nous rappelons dans la suite les principes de la théorie des croyances [Shaf-76] [Lowr-91] [Bloc-96b] [Jane-97], avant de détailler son application à l'analyse des images radar.

Considérons  $\Theta$  un espace d'événements ou d'hypothèses simples. Pour notre application, une hypothèse simple correspondra à l'appartenance à une des classes  $C_i$  du tableau

8.1. Dans la suite, nous adoptons des notations ensemblistes pour les propositions logiques : la disjonction ("OU" logique) entre les hypothèses  $A$  et  $B$  est notée  $A \cup B$ , la conjonction ("ET" logique)  $A \cap B$ , la négation  $\bar{A}$ , et l'implication de  $A$  par  $B$ ,  $B \subset A$ .

A partir de  $\Theta$ , on peut construire l'ensemble de tous les sous-ensembles de  $\Theta$ , noté  $2^\Theta$  qui contient toutes les combinaisons d'hypothèses possibles. Par exemple, si  $\Theta = \{h_1, h_2, \dots, h_N\}$ , alors :

$$2^\Theta = \{\emptyset, \{h_1\}, \dots, \{h_N\}, \{h_1, h_2\}, \dots, \Theta\}$$

Toutes les hypothèses de  $2^\Theta$  qui ne sont pas simples sont dites composées (par exemple  $\{h_2, h_4, h_N\} = \{h_2\} \cup \{h_4\} \cup \{h_N\}$ ).

### 8.2.1 Masse, crédibilité, plausibilité

On définit une fonction de masse  $m$  pour une source d'informations par une fonction de  $2^\Theta$  dans  $[0, 1]$  telle que :

$$m(\emptyset) = 0, \text{ et } \sum_{A \in 2^\Theta} m(A) = 1$$

Cette définition présente de grandes similitudes avec celle d'une distribution de probabilités, mais la masse totale de 1 est répartie sur tous les éléments de  $2^\Theta$ , ce qui permet de tenir compte de l'ignorance par exemple entre deux hypothèses  $A$  et  $B$  par l'intermédiaire de  $A \cup B$ .

Les éléments de masse non nulle sont dits éléments focaux. Si les seuls éléments focaux sont les singletons (c'est-à-dire par exemple les classes du tableau 8.1), nous retrouvons une probabilité bayésienne. La définition de la fonction de masse représente toute la connaissance et l'ignorance disponibles par la source d'information considérée. En effet, la masse  $m(A)$  reflète la partie de croyance attribuée exactement à l'hypothèse  $A$  ; s'il s'agit d'une hypothèse composée, elle intègre donc l'incapacité à différencier les différentes hypothèses singletons. Par exemple, la masse  $m(\{h_i\} \cup \{h_j\})$  représente la masse pouvant aller potentiellement à  $\{h_i\}$  ou  $\{h_j\}$  sans qu'on puisse pour l'instant, en l'état des connaissances, trancher entre ces deux hypothèses. Ainsi, dans le cas extrême d'ignorance totale sur toutes les hypothèses pour la source, la masse se définit par :

$$m(\Theta) = 1, \text{ et } \forall A \neq \Theta, m(A) = 0$$

Avec la fonction de masse, sont définies deux autres fonctions : la crédibilité  $Cr$  et la plausibilité  $Pls$ . En effet,  $m(A)$  ne représente que la masse dédiée exactement à  $A$ . Cependant, si  $A \cap B \neq \emptyset$ , la masse commune à  $A$  et  $B$  est potentiellement attribuable à  $A$  ou à un sous-ensemble de  $A$ . Ainsi, la plausibilité est définie par :

$$Pls(A) = \sum_{B \in 2^\Theta / A \cap B \neq \emptyset} m(B)$$

et représente la masse totale potentiellement attribuable à  $A$  ou partie. La plausibilité établit donc dans quelle mesure les informations de la source ne contrarient pas une hypothèse.

De la même façon, la masse d'une hypothèse  $B$  contenue dans  $A$  conforte  $A$ . On définit donc la crédibilité de  $A$  par :

$$Cr(A) = \sum_{B \in 2^\Theta / B \subset A} m(B)$$

La crédibilité établit dans quelle mesure les informations de la source soutiennent  $A$ . Notons qu'une hypothèse composée est donc forcément plus crédible que les hypothèses simples qu'elle contient.

Ces fonctions ont les propriétés suivantes :

$$Cr(\Theta) = 1 \text{ et } Cr(\emptyset) = 0$$

$$Pls(\Theta) = 1 \text{ et } Pls(\emptyset) = 0$$

$$Cr(A) \leq Pls(A) \quad \forall A \in \Theta$$

$$Pls(A) = 1 - Cr(\bar{A})$$

En fait, la longueur de l'intervalle  $[Cr(A), Pls(A)]$ , appelé intervalle de croyance, quantifie l'ignorance de la source sur l'hypothèse  $A$ . Cet intervalle est donc réduit à 0 pour une ignorance nulle (cas bayésien), et à 1 pour une ignorance totale (la source n'apporte aucune information). Il peut être interprété comme l'imprécision de la source sur la valeur de la vraie "probabilité" de  $A$ .

## 8.2.2 Règle orthogonale de Dempster

Nous avons jusqu'ici considéré une seule source d'informations modélisée par sa fonction de masse. Si nous avons plusieurs sources à notre disposition, il faut pouvoir combiner leurs informations. C'est le rôle de la règle de combinaison orthogonale de Dempster.

Considérons deux sources  $S_1$  et  $S_2$  de fonctions de masses  $m_1$  et  $m_2$  définies sur le même espace d'événements  $\Theta$ . On définit alors la masse  $m_{12} = m_1 \oplus m_2$  résultant de la combinaison par :

$$m_{12}(A) = \sum_{B_1, B_2 / B_1 \cap B_2 = A} m_1(B_1)m_2(B_2)$$

Sous cette forme, s'il existe des éléments focaux dont la conjonction est vide ( $B_1 \cap B_2 = \emptyset$ ), la masse  $m_{12}(\emptyset)$  sera non nulle. Pour rester cohérent avec la définition de la fonction de masse donnée précédemment, il faut donc d'une part définir  $m_{12}(\emptyset) = 0$  et d'autre part normaliser en divisant par  $1 - k_{12}$ , où  $k_{12}$  est la masse du vide définie par :

$$k_{12} = \sum_{B_1, B_2 / B_1 \cap B_2 = \emptyset} m_1(B_1)m_2(B_2)$$

et cela dans le cas où  $k_{12} < 1$ .  $k_{12}$  mesure le conflit entre les deux sources d'informations. Lorsqu'il est égal à 1, les deux sources sont totalement conflictuelles, ce qui rend impossible leur combinaison.

Affecter une masse nulle à l'ensemble vide et, par voie de conséquence, effectuer la normalisation, revient à se placer dans un contexte de monde fermé, c'est-à-dire que les hypothèses considérées sont les seules solutions possibles au problème. Cette façon de procéder introduit de graves incohérences dès que cette hypothèse n'est pas vérifiée, et plusieurs solutions ont été proposées [Dubo-82] [Yage-83] [Yage-85] [Oblo-85] [Dubo-88] [Smet-90] [Jane-97]. Une des solutions consiste simplement à relâcher la contrainte  $m(\emptyset) = 0$  et à considérer l'ensemble vide comme comprenant toutes les hypothèses qui ne sont pas envisagées dans  $\Theta$ . Pour notre application, l'ensemble vide correspondra à la classe de rejet<sup>3</sup>.

La formule de la somme orthogonale de Dempster, éventuellement normalisée, se généralise à  $n$  sources :

$$m_{12\dots n}(A) = m_1 \oplus m_2 \oplus \dots \oplus m_n(A) = \sum_{B_1, B_2, \dots, B_n / B_1 \cap B_2 \cap \dots \cap B_n = A} m_1(B_1)m_2(B_2)\dots m_n(B_n)$$

Cette règle est commutative et associative, et donc les sources peuvent être combinées deux à deux. Cette propriété est particulièrement importante puisque l'ajout d'un opérateur se ramène simplement à une combinaison supplémentaire de sa masse avec la masse déjà combinée.

La règle de combinaison a une interprétation intuitive : elle permet de transférer les masses potentielles d'une hypothèse composée sur ses éléments constituants en fonction d'une nouvelle information. Par exemple, l'incapacité d'une source d'informations à trancher entre les hypothèses  $A$  et  $B$ , qui se traduit par une masse non nulle sur  $A \cup B$ , peut être compensée par l'information d'une autre source soutenant  $A$  en transférant la masse commune sur  $A$ . Plus généralement, l'apport de nouvelles informations permet au fur et à mesure d'affecter de plus en plus précisément les masses, selon un consensus général entre les sources. Si toute l'information nécessaire était disponible, seules les hypothèses singletons auraient à la fin une masse non nulle.

Notons qu'il est possible de prendre en compte des différences de fiabilité entre les sources en attribuant une masse à  $\Theta$ , ce qui correspond à une ignorance globale sur une source.

En plus des trois fonctions (masse, crédibilité, plausibilité), on en définit souvent une quatrième, la communalité :

$$Q(A) = \sum_{A \subset B} m(B)$$

En effet, la combinaison de  $n$  sources s'écrit alors pour cette fonction :

$$Q_{12\dots n}(A) = K \prod_{i=1}^n Q_i(A)$$

où  $K = \frac{1}{1 - k_{12\dots n}}$  est, comme précédemment, une constante de normalisation lorsqu'on se place dans un contexte normalisé. Cette fonction est souvent utilisée pour des aspects techniques dans les preuves des théorèmes.

3. Cette solution n'est pas idéale puisqu'elle amène à confondre l'ensemble vide et une "hypothèse extérieure" qui n'a pas été prise en compte dans  $\Theta$  (notre classe de rejet). Ainsi  $A \cap B = \emptyset$  peut alors signifier que  $A \cap B$  est réellement vide ou que leur intersection correspond à l'"hypothèse extérieure", ce qui n'a pas la même signification. Nous n'introduirons cependant pas cette distinction puisque les résultats finalement obtenus sont équivalents [Dubo-88].

La complexité du calcul des fonctions masse, crédibilité, plausibilité ou communalité étant exponentielle par rapport au cardinal de  $\Theta$ , des méthodes de calculs accélérés ont été proposées dans des cas particuliers (lorsque chaque source renseigne sur un événement et son complémentaire [Barn-81], ou lorsqu'on ne s'intéresse qu'aux plausibilités de certaines hypothèses dites atomiques relativement aux sources d'informations dont on dispose [Barn-91]).

### 8.2.3 Critère de décision

Connaissant la masse, la crédibilité et la plausibilité des hypothèses, il s'agit ensuite de prendre une décision. Dans un cadre bayésien, l'hypothèse ayant la probabilité maximale est souvent choisie. Dans le cadre de la théorie des croyances, plusieurs choix sont possibles (généralement sur les seules hypothèses simples) :

- maximum de crédibilité : décision selon un schéma "pessimiste"
- maximum de plausibilité : décision selon un schéma "optimiste"
- maximum de leur moyenne : compromis
- etc.

Ces différents choix conduisent à des résultats différents et dépendent de l'application considérée. Dans notre cas, pour pouvoir utiliser par la suite un cadre bayésien et introduire des relations contextuelles en définissant un champ Markovien, nous souhaitons nous ramener à des probabilités. Aussi adoptons-nous ici la démarche de Smets [Smet-95] qui distingue deux niveaux de représentation de la croyance : celui ("credo") où se forge l'opinion, la croyance, et celui ("pignus") où il faut prendre une décision, parier. Smets définit ce qu'il appelle la transformation pignistique pour passer du niveau de la croyance (masse, crédibilité et plausibilité) à celui de la décision. Ainsi, la probabilité pignistique  $BetP$  s'obtient en répartissant chaque masse d'une hypothèse composée sur les hypothèses simples qui la composent (en l'absence d'informations complémentaires, on suppose la masse équirépartie sur les hypothèses simples) :

$$BetP(\{h_i\}) = \sum_{A/\{h_i\} \subset A} \frac{m(A)}{card(A)} \quad (8.1)$$

La décision s'effectue ensuite en choisissant  $\{h_i\}$  maximisant  $BetP$  (schéma "prudent").

## 8.3 Application de la théorie des croyances pour l'interprétation des images radar

Nous montrons dans cette partie comment la théorie de Dempster-Shafer apporte une solution au problème de l'interprétation globale des images radar. Plus généralement, alors que ce cadre théorique a souvent été appliqué à la fusion multi-sources, nous apportons une nouvelle preuve qu'il est également bien adapté à la fusion des informations extraites par différents opérateurs sur une même image. En outre, contrairement à de nombreuses applications, nous traitons un nombre de sources relativement grand. En nous plaçant dans un

cadre "monde ouvert", nous exploitons aussi l'information contenue dans la masse attribuée à l'ensemble vide qui est assimilé à une classe de rejet. En s'appuyant sur des primitives régions sans contenu sémantique, notre application se situe à un niveau intermédiaire entre le bas niveau qui correspondrait à une fusion en chaque pixel et un haut niveau pour lequel les objets fusionnés auraient déjà été interprétés.

Les paragraphes suivants décrivent comment sont définies les primitives sur lesquelles nous travaillons, et les fonctions de masse pour chaque opérateur, avec  $\Theta = \{\text{relief, route, fleuve, forêt, homogène, ville, industriel, champ clair}\}$ . Après avoir illustré les avantages de la théorie de la croyance sur un exemple, nous abordons quelques aspects pratiques d'implantation.

### **8.3.1 Définition des régions**

Nous définissons dans cette partie les régions de l'image qui seront considérées comme primitives dans toute la suite et sur lesquelles sera effectuée la fusion. Cette étape est liée au choix des classes sémantiques et des images traitées. Dans notre application cartographique satellitaire, aucune classe ne justifie une précision au niveau du pixel, d'ailleurs illusoire compte tenu des opérateurs qui sont utilisés. Mais cette étape mise à part, l'ensemble de la méthode décrite ci-dessous est parfaitement applicable avec d'autres primitives.

Nous cherchons ici à regrouper des pixels de même radiométrie en régions. Pour ce faire, nous proposons d'utiliser le résultat de la segmentation markovienne décrite au chapitre 6, et de travailler sur les régions (composantes connexes) délimitées. Néanmoins, comme ce résultat est relativement imprécis et peut relier deux régions de même radiométrie initialement séparées par une structure linéaire trop fine, nous réalisons une sur-segmentation à partir du résultat obtenu. Cela est réalisé par les étapes suivantes :

- segmentation markovienne automatique de l'image (chapitre 6) ;
- détection des frontières des régions de la segmentation ;
- calcul d'une carte de distances relativement aux frontières ;
- ligne de partage des eaux sur le négatif de l'image de distances ; les frontières à une distance 0 passent en effet à la valeur maximum sur le négatif de l'image et sont donc des lignes de crête lors du calcul des lignes de partage des eaux.

Les étapes de l'algorithme sont illustrées sur la figure 8.3.

De plus, comme nous nous intéressons à des structures linéaires fines pour le réseau routier et les structures de relief, et que celles-ci ont pu être mal segmentées, nous ajoutons aux frontières obtenues par les lignes de partage des eaux (fig.8.4a) les frontières des objets linéaires détectés :

- lignes brillantes (détectées par le détecteur de lignes du chapitre 2, fig.8.4b) ;
- routes (détectées par la méthode proposée au chapitre 4, fig.8.4c) ;
- fleuves (détectés par la méthode proposée au chapitre 4).

Seuls les fleuves sont exactement détectés comme au chapitre 4. Pour les routes et les lignes de relief, une plus grande tolérance est admise puisque la fusion avec les autres opérateurs apportera des informations supplémentaires (voir §8.3.2).

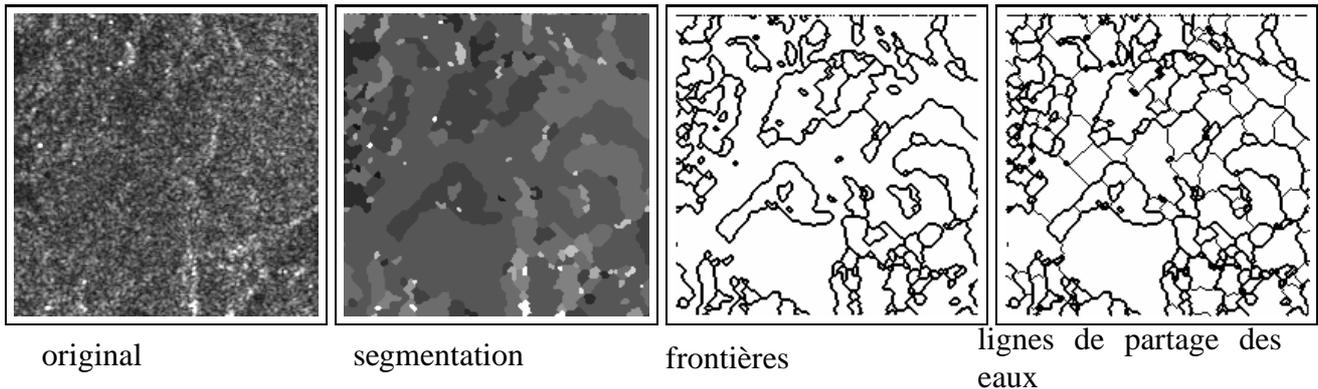


FIG. 8.3 – Étapes de l’algorithme de sur-segmentation

Les régions délimitées par l’ensemble de ces frontières seront traitées par la suite (fig.8.4d). Remarquons que la solution utilisée, qui consiste à plaquer tous les objets linéaires, est discutable. En effet, on pourrait envisager de conserver ces objets dans leur intégralité et de les considérer comme des régions à part entière, mais alors la définition des fonctions de masse sur ces objets serait problématique puisqu’ils traverseraient des régions avec des réponses très différentes.

### 8.3.2 Définition des fonctions de masses

Cette partie est cruciale pour le traitement de la fusion. En effet, une fois choisi le cadre de la théorie des croyances, toute la complexité du problème est ramenée au choix des fonctions de masse de chaque opérateur  $O_j$ . La fusion proprement dite s’effectue ensuite avec la règle de fusion qu’est la somme orthogonale de Dempster - Shafer.

Dans le cas d’une classification mono-source, chaque opérateur est considéré comme une source d’informations. Pour chaque réponse  $x$  de l’opérateur  $O_j$  et chaque hypothèse de classe  $A$ ,  $A$  pouvant être une des classes  $C_i$  ou une union de ces classes, il nous faut définir une fonction de masse  $m_j(A)(x)$ . Pour  $N$  classes, il y a au total  $2^N$  hypothèses à considérer, et donc autant de masses à définir a priori pour chaque opérateur et chacune de ses réponses. En pratique, seules quelques-unes de ces hypothèses seront des éléments focaux.

Dans le cas de notre application, il nous faut tout d’abord définir les opérateurs que nous allons considérer. La plupart d’entre eux sont déduits directement des détecteurs définis dans les chapitres précédents (de la partie I pour les structures linéaires, et de la partie II pour les régions). Ces détecteurs donnent une réponse essentiellement binaire (absence ou présence d’une classe à laquelle ils sont dédiés) ; nous cherchons donc à leur associer une mesure de confiance. Nous parlerons alors plutôt d’opérateurs lorsque la réponse varie dans une certaine plage de valeurs. Nous déduirons ensuite les fonctions de masse à partir de ces mesures de confiance et de notre connaissance du comportement des opérateurs pour choisir les éléments focaux. Répétons que c’est cette étape de modélisation qui est la plus importante, puisqu’une fois les masses définies, la règle de combinaison de Dempster s’applique telle que définie au §8.2.2.

**a. Définition de mesures de confiance pour chaque détecteur : définition des opérateurs**

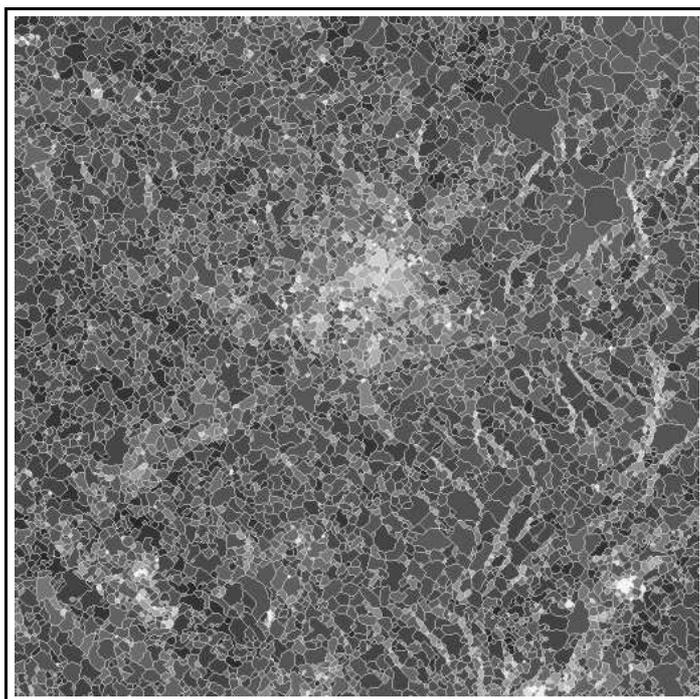
Cette étape est essentiellement liée à la nature des outils développés pour traiter et extraire des informations de l'image. La sortie de certains détecteurs est en effet déjà quantifiée sur plusieurs valeurs, et celles-ci peuvent directement être considérées comme des mesures de confiance en la détection. Pour d'autres, la sortie est binaire, par exemple lorsqu'elle représente le résultat d'un étiquetage.

Nous allons dans ce paragraphe passer en revue les différents outils développés pour notre application et leur associer une mesure de confiance, le cas échéant. Nous associons à chaque opérateur  $O_j$  un espace de définition  $\mathcal{D}_j$  dans lequel ses réponses prennent leurs valeurs.

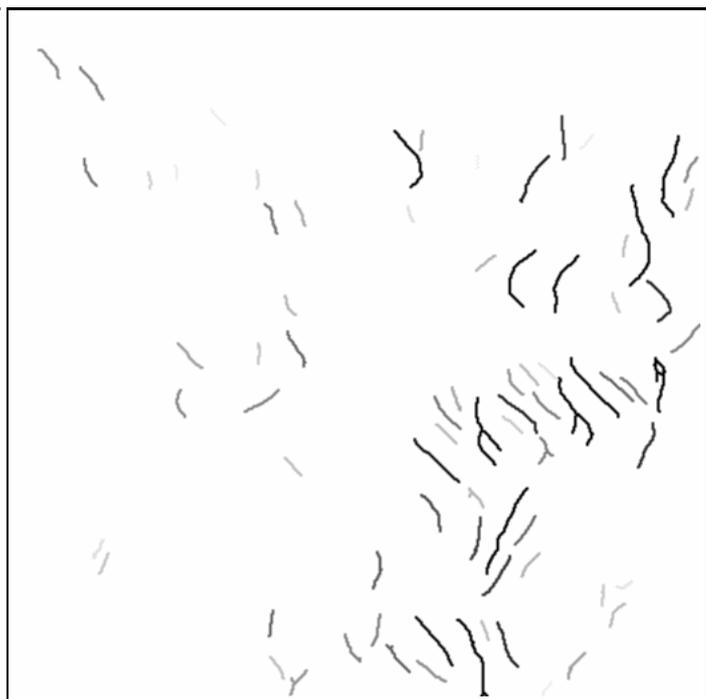
- **Opérateur "ffmax"** : la sortie de cet opérateur (les différentes valeurs de  $k$ ) est naturellement quantifiée (cf. chapitre 7). Nous avons choisi de prendre une dynamique des réponses sur dix niveaux :  $\mathcal{D}_{\text{ffmax}} = \{1, \dots, 10\}$ .
- **Opérateur " $\sigma_{\text{MAR}}$ "** : la sortie de cet opérateur qui est l'écart-type du modèle log-normal auto-régressif local prend ses valeurs dans l'espace des réels positifs  $\mathcal{D}_{\sigma_{\text{MAR}}} = [0; +\infty[$ .
- **Opérateur "routes"** : nous avons pour l'instant défini un détecteur de routes à sortie binaire, résultat de l'étiquetage du graphe de segments. Nous cherchons donc à associer à chaque route (i.e chaîne de segments) détectée une mesure de confiance qui sera prise en compte lors de la fusion. Une solution naturelle liée à l'utilisation du cadre markovien consiste à calculer la variation énergétique  $\Delta U$  entre la configuration "nulle" et la configuration "route" obtenue (cf. chapitre 3, section 3.5). La configuration "nulle" correspond à un étiquetage au label "non route" des segments constituant la route détectée. Plus cette variation énergétique est élevée<sup>4</sup>, plus la configuration "route" est justifiée comparativement à la configuration "nulle", et plus la chaîne de segments détectée est fiable. L'énergie de la configuration est liée à plusieurs caractéristiques de la chaîne de segments : sa longueur, les angles entre deux segments consécutifs, les potentiels de chaque segment. Le cas extrême correspond au cas où ces deux configurations ont la même énergie, cas pour lequel il n'y a pas plus de raison de garder la route que de la supprimer. Nous considérons donc  $\Delta U$  comme un indice de fiabilité associé à chaque route : ainsi,  $\mathcal{D}_{\text{routes}} = [0; +\infty[$ . Les valeurs prises par cet indice varient avec les images traitées, mais on peut dire d'une façon expérimentale que  $\Delta U > 0,3$  caractérise une route fiable. Un exemple des variations de  $\Delta U$  est donné figure 8.4c (en négatif). Les niveaux de gris entre 0 et 255 des routes sont obtenus par étalement de l'intervalle de variation  $[0; 0,3]$ , les valeurs supérieures à 0,3 étant mises à 255.
- **Opérateur "lignes brillantes"** : sa sortie était également binaire suite à plusieurs opérations de seuillage. Nous définissons une mesure de confiance sur les lignes de relief détectées (cf. chapitre 4<sup>5</sup>, section 4.3) en prenant en compte leur longueur (calculée sur le squelette) et

4. Cette variation énergétique est nécessairement positive. Dans la cas contraire, cela signifierait que l'étiquetage au label "non route" de la chaîne de segments a une énergie plus faible que son étiquetage au label "route". Ainsi, la configuration obtenue en fin du recuit simulé ne correspondrait pas au minimum global de l'énergie.

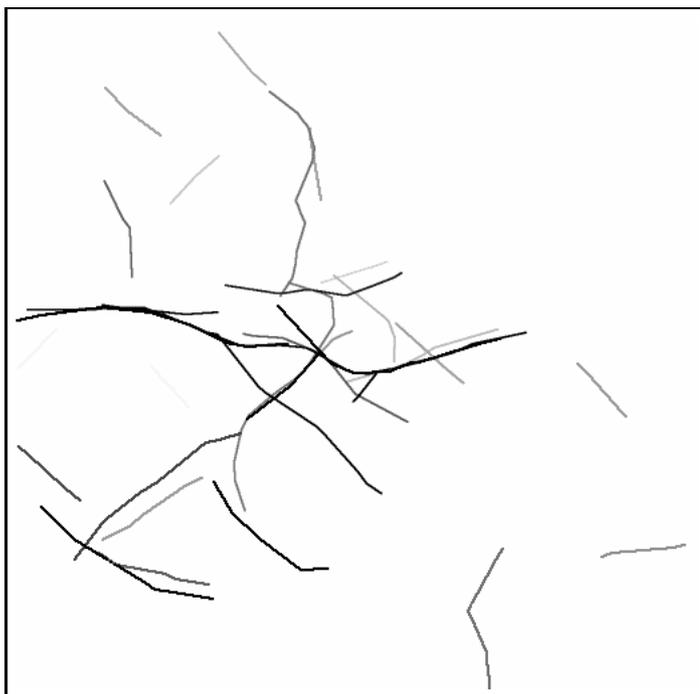
5. L'étape de regroupement décrite au chapitre 4 n'est pas effectuée ici et toutes les lignes détectées sont conservées.



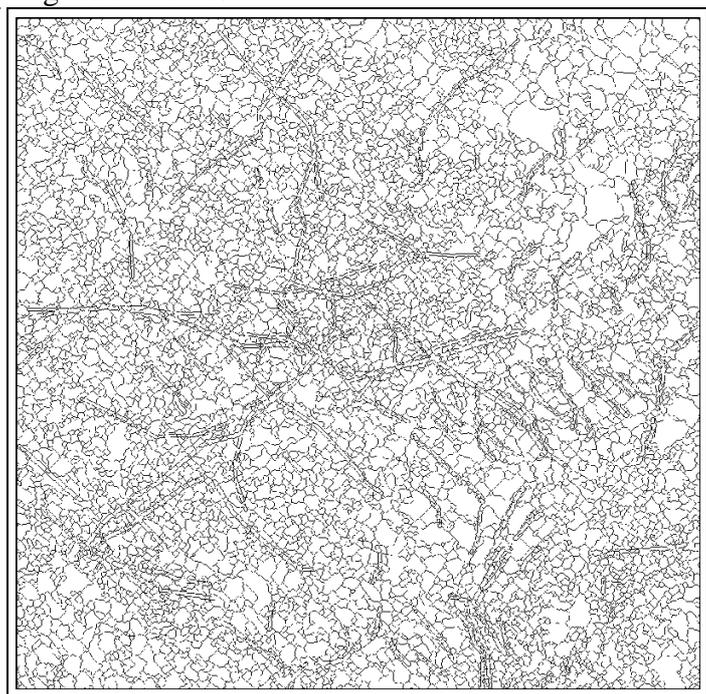
a. Sur-segmentation



b. Négatif des mesures de confiance de l'opérateur "lignes brillantes"



c. Négatif des mesures de confiance de l'opérateur "routes"



d. Régions

FIG. 8.4 – Définition des régions et négatif des mesures de confiance sur l'image d'Aix-en-Provence

la réponse moyenne du détecteur de lignes. Ces deux critères sont fusionnés en utilisant une somme associative symétrique, et donc  $\mathcal{D}_{\text{lignes brillantes}} = [0; 1]$  (cf. chapitre 2 et figure 8.4b).

- **Opérateur "échos forts"**: (défini au §7.2.2) là encore, un ensemble de seuils était utilisé pour réaliser la détection. Une mesure de confiance associée à chaque zone détectée peut être simplement proportionnelle au nombre d'échos forts qui la constituent :  $\mathcal{D}_{\text{échos forts}} = [0; +\infty[$ .

- **Opérateur "fleuves"**: la sortie de cet opérateur est binaire. La part de haut niveau intervenant dans ce détecteur, à plus forte raison encore que pour les routes, est telle qu'il est difficile de définir une mesure de confiance. Nous avons donc simplement conservé l'image binaire. D'autre part, cette détection est effectuée avant celle des routes et les cours d'eau détectés sont masqués pour ne pas influencer la détection des routes<sup>6</sup> :  $\mathcal{D}_{\text{fleuves}} = \{0, 1\}$ .

Ces différentes mesures de confiance sont définies en chaque pixel. Pour définir les mesures associées à chaque région, nous avons effectué un simple moyennage sur les mesures des pixels de la région pour la plupart des opérateurs, ou plus rarement pris la mesure maximale (pour les objets linéaires).

**b. Modélisation du problème : définition des masses**

Il nous faut maintenant définir les fonctions de masse  $m_i$  de l'opérateur (ou source)  $O_i$  pour chacune de ses réponses. Dans notre application, nous emploierons dans la suite les notations suivantes pour les différentes classes  $C_i$  (ou hypothèses singletons) (tab. 8.2) :

TAB. 8.2 – Notations

Classes	<i>relief</i>	<i>route</i>	<i>fleuve</i>	<i>homogène mer ∪ forêt</i>	<i>ville (dense)</i>	<i>industriel</i>	<i>champ clair</i>
Notations	<i>Re</i>	<i>Ro</i>	<i>Fl</i>	<i>H</i>	<i>V</i>	<i>I</i>	<i>Cl</i>

L'hypothèse contraire d'une hypothèse  $A$ , complémentaire de  $A$  dans  $2^\Theta$ , est notée  $\bar{A}$ .

- **Choix des éléments focaux :**

La définition des fonctions de masse d'un opérateur passe avant tout par le choix de ses éléments focaux. Ce choix est primordial car il reflète précisément la part d'informations apportée par une source. Dans de nombreux cas, un opérateur  $O_j$  est dédié à la détection d'une classe  $C_i$ . Si cet opérateur est suffisamment précis, il renseigne sur l'appartenance à la classe  $C_i$  et à son complémentaire  $\bar{C}_i$ . Par conséquent, ces deux hypothèses seront des éléments focaux de la source  $O_j$ . En outre, ce seront les seuls si l'opérateur est précis. En réalité, dans la majorité des cas l'opérateur n'est pas suffisamment précis et il faut tenir compte d'autres classes pour définir les éléments focaux. Plusieurs situations sont possibles : l'opérateur n'est pas précis car il n'est pas capable de discriminer certaines classes (par construction); ou bien l'opérateur n'est pas précis au niveau de la localisation des classes détectées et va pouvoir englober des régions appartenant à d'autres classes (parce que la fenêtre de calcul de sa réponse est de grande taille par exemple). Ces deux cas sont fréquents dans la plupart des problèmes et sont illustrés dans le cas de notre application où nous

6. Cela revient à détecter en priorité les objets les plus faciles [Houz-94].

expliquons pour chaque opérateur le choix des éléments focaux.

- opérateurs "routes", "lignes brillantes" et "fleuves" : ils discriminent les classes *route*, *relief* et *fleuve* respectivement contre toutes les autres classes, donc une hypothèse simple contre son complémentaire. Les éléments focaux sont donc  $Re$  et  $\overline{Re}$ ,  $Ro$  et  $\overline{Ro}$ ,  $Fl$  et  $\overline{Fl}$ .
- opérateur "échos forts" : cet opérateur est intrinsèquement très imprécis quant à la localisation des régions. Il ne fait en effet que regrouper des échos forts dans des zones d'influence (cf. chapitre 7), sans précision aucune quant aux frontières de ces zones. Ainsi, les régions de forte réponse de cet opérateur peuvent aussi bien s'étaler sur des régions d'urbain plus dense (redondance avec l'opérateur "ffmax") qu'englober les routes qui traverseraient des villes ou des zones industrielles. Cet opérateur est donc par construction incapable de différencier précisément les classes *industriel*  $I$ , *ville*  $V$  et *route*  $Ro$ . En revanche les zones de faibles réponses n'appartiennent sûrement pas aux zones industrielles, et donc elles appartiennent à son complémentaire. Nous choisissons donc pour éléments focaux  $(Ro \cup V \cup I)$  et  $\overline{I}$ , puisque ce sont les classes sur lesquelles nous renseigne cet opérateur. Ce choix des éléments focaux nous permet donc de tenir compte de l'incertitude par les valeurs des fonctions de masse (cf. paragraphe suivant), mais aussi de l'imprécision par le choix des éléments focaux.
- opérateur "ffmax" : là encore, l'imprécision est intrinsèquement liée à la nature de l'opérateur. D'une part, comme déjà mentionné, cet opérateur répond aussi bien sur les zones d'urbain dense que sur les champs brillants (cf. l'exemple sur l'image de Lorient) qu'il n'est donc pas capable de discriminer (cela est dû à l'aspect comparable de ces deux classes sur les images radar) ; d'autre part, comme précédemment, cet opérateur est par construction imprécis quant à la localisation des réponses puisqu'il exploite l'information d'une fenêtre de 40 par 40 pixels. Donc, comme précédemment, des régions plus industrielles et des routes peuvent être englobées dans les régions de fortes réponses. En revanche, en l'absence de réponse, il ne peut pas s'agir des deux classes *ville* ou *champ clair* qu'est capable de détecter cet opérateur. Aussi, les éléments focaux finalement choisis sont :  $(Ro \cup V \cup I \cup Cl)$  et  $(\overline{V} \cap \overline{Cl}) = (Re \cup Ro \cup Fl \cup H \cup I)$ . Là encore, c'est le choix des éléments focaux qui tient compte de l'imprécision de l'opérateur.
- opérateur " $\sigma_{MAR}$ " : le même raisonnement que pour les deux opérateurs précédents s'applique. En effet, la résolution fortement dégradée à laquelle sont calculées ses réponses conduit à une confusion possible entre la forêt et les routes fines pour les faibles réponses (celles-ci peuvent être assimilées à des zones homogènes à cause du fort moyennage). En revanche les fortes valeurs correspondent assurément à des zones hétérogènes. Les éléments focaux choisis sont donc  $(Ro \cup H)$  et  $\overline{H}$ . Nous aurions pu considérer d'autres éléments focaux pour tenir compte des très fortes réponses de cet opérateur qui correspondent à des régions plutôt industrielles. Néanmoins, cette information étant systématiquement moins fiable que celle délivrée par l'opérateur "échos forts", nous avons préféré ne pas l'intégrer dans notre modélisation.

• **Choix des fonctions de masse :**

Bien que développée pour pallier les insuffisances de la théorie des probabilités, l'étape de définition des masses dans la théorie des croyances s'appuie très souvent sur des probabilités ou des distances par rapport à un centre de classe [Lee-87] [Zahz-92] [LeHe-97], en particulier lorsqu'il s'agit de fusion au niveau du pixel. Dans le cas où aucune information n'est disponible sur la forme a priori des fonctions de masse, il est nécessaire de réaliser une étape d'apprentissage à partir d'échantillons représentatifs des classes. Lorsque les sources d'informations proviennent de différents traitements appliqués à une même image comme dans notre cas, il est difficile de supposer une distribution particulière pour les fonctions de masse. Nous proposons donc d'étudier les fréquences des réponses des opérateurs sur des zones tests et d'en déduire les fonctions de masse associées.

• **Définition des zones tests :** des échantillons de chaque classe d'intérêt ont été sélectionnés manuellement sur des images de notre base de données ERS-1. Nous nous sommes volontairement limités à deux images (celle d'Aix-en-Provence et celle de Lorient) pour sélectionner ces zones tests afin de valider la fiabilité de la méthode en n'effectuant l'apprentissage que sur un petit nombre d'échantillons. Ceux-ci ont été choisis pour représenter les classes ou les unions de classes sur lesquelles renseigne chaque opérateur. On notera dans la suite  $E_j^i$  un échantillon représentatif de l'élément focal  $i$  de l'opérateur  $O_j$ . Les tableaux 8.3 et 8.4 donnent la taille et quelques statistiques sur les échantillons sélectionnés.

• **Méthode d'apprentissage :** pour chaque opérateur  $O_j$ , les fréquences des réponses sur les échantillons représentant ses éléments focaux sont étudiées (après normalisation par la fréquence maximum de l'échantillon [Chau-95]). La forme des courbes de fréquences permet de déduire la forme des fonctions de masses, avec la contrainte de normalisation des masses (la somme des masses sur les éléments focaux doit être égale à  $1^7$ ). Nous avons choisi d'imposer des fonctions de masse linéaires par morceaux (trapézoïdales) et d'utiliser l'apprentissage seulement pour choisir de façon supervisée les paramètres nécessaires à leur définition. Les résultats donnés en fin de ce chapitre montreront que cette approximation s'est révélée suffisante pour notre application et que les fonctions de masses se sont montrées adaptées aux différentes images traitées. Cela est en partie lié à la simplicité des opérateurs qui discriminent essentiellement une classe contre son contraire d'une part, et d'autre part aux zones de transition des fonctions de masse qui les rendent robustes aux faibles variations.

• **Cas de l'application aux images radar :** nous détaillons dans la suite les résultats obtenus au cours de l'apprentissage et les fonctions de masse qui ont été déduites.

◇ *Opérateur "ffmax"* : comme il était prévisible et comme indiqué sur la figure 8.5, les réponses les plus fréquentes sur les échantillons correspondant à l'élément focal ( $Ro \cup I \cup Cl \cup V$ ) sont des valeurs élevées (courbes 8.5a et c), et faibles au contraire pour l'élément ( $\overline{V} \cap \overline{Cl}$ ) (courbes 8.5b et d). Les fonctions de masse trapézoïdales qui en sont déduites sont indiquées sur la figure 8.5e.

◇ *Opérateur  $\sigma_{MAR}$*  : de la même façon, les fréquences empiriques confortent le comportement attendu de l'opérateur (fig. 8.6). Les échantillons représentatifs des zones homogènes (forêt ou mer englobant éventuellement des routes), donc de l'élément focal ( $H \cup Ro$ ), donnent

7. Cette contrainte est relâchée pendant le processus de fusion, mais pas pour la définition des masses.

TAB. 8.3 – Statistiques et population des échantillons sélectionnés sur l'image 1 (Aix-en-Provence) -  $\gamma$  pour coefficient de variation.

zone	min	max	pop.	moy.	media.	ecart-ty.	var.	$\gamma$	ske.	kurt.
Image	12	16655	1024 <sup>2</sup>	290	260	170	28143	0.59	10.76	517.75
forêt										
fo.1	40	1473	39585	272	262	93	8573	0.34	0.78	5.58
fo.2	19	930	28742	283	274	96	9192	0.34	0.69	4.07
fo.3	48	562	3643	246	240	76	5737	0.31	0.43	3.06
fo.4	56	719	4085	269	258	94	8863	0.35	0.74	3.80
indus.										
ind.1	29	4182	7727	355	313	206	42331	0.58	4.82	65.10
ind.2	20	4405	6557	409	357	242	58459	0.59	3.84	36.09
ind.3	36	3503	6746	332	282	209	43766	0.63	4.14	36.39
ind.4	48	3961	15761	342	303	189	35590	0.55	3.54	35.69
ind.5	43	1865	14422	384	352	176	30993	0.46	1.81	9.96
ind.6	46	3092	11926	367	330	195	38012	0.53	3.06	24.17
ind.7	49	7241	8042	416	371	259	66832	0.62	8.67	178.48
ind.8	31	3312	8286	341	300	189	35631	0.554	2.945	25.667
ville										
vil.1	46	4194	26080	464	407	267	71113	0.58	3.08	24.06
vil.2	52	9240	4261	546	364	607	369025	1.11	4.79	39.04
vil.3	68	10241	4949	512	364	570	325603	1.11	5.89	57.08

surtout de faibles réponses (fig. 8.6a et c) alors que des valeurs plus élevées sont obtenues sur  $\bar{H}$  (fig. 8.6b et d). Les fonctions de masse déduites représentent une approximation plus grossière des réponses que donnée précédemment. En outre, la classe homogène est légèrement favorisée pour éviter qu'une trop grande partie de l'image soit classée dans la classe de rejet  $C_o$ . En pratique, pour compenser ce biais en faveur de la forêt, ou plus généralement de la classe *homogène*, celle-ci sera indiquée dans les résultats avec le niveau de confiance associé.

◇ *Opérateur "échos forts"* : là encore, les fréquences empiriques confortent le comportement attendu de l'opérateur, mais à cause du seuillage effectué pour ramener la dynamique des réponses entre 0 et 255, celui-ci est plus marqué que précédemment (fig. 8.7). Les échantillons représentatifs des zones industrielles (englobant éventuellement des routes ou débordant sur de l'urbain plus dense), donc de l'élément focal ( $I \cup V \cup Ro$ ), donnent de très fortes réponses (pic marqué à 255) alors que des valeurs très faibles sont obtenues sur  $\bar{I}$  (pic marqué à 0). Néanmoins, pour préserver des valeurs intermédiaires entre les valeurs extrêmes 0 et 255, nous avons choisi de définir les fonctions de masse avec une très grande plage de transition, comme indiqué sur la figure 8.7.

◇ *Opérateurs "routes", "fleuves" et "lignes brillantes"* : il est difficile de définir des échantillons représentatifs de ces classes. Pour les routes, une grande partie d'entre elles n'est pas

TAB. 8.4 – *Statistiques et population des échantillons sélectionnés sur l'image 2 (Lorient) -  $\gamma$  pour coefficient de variation.*

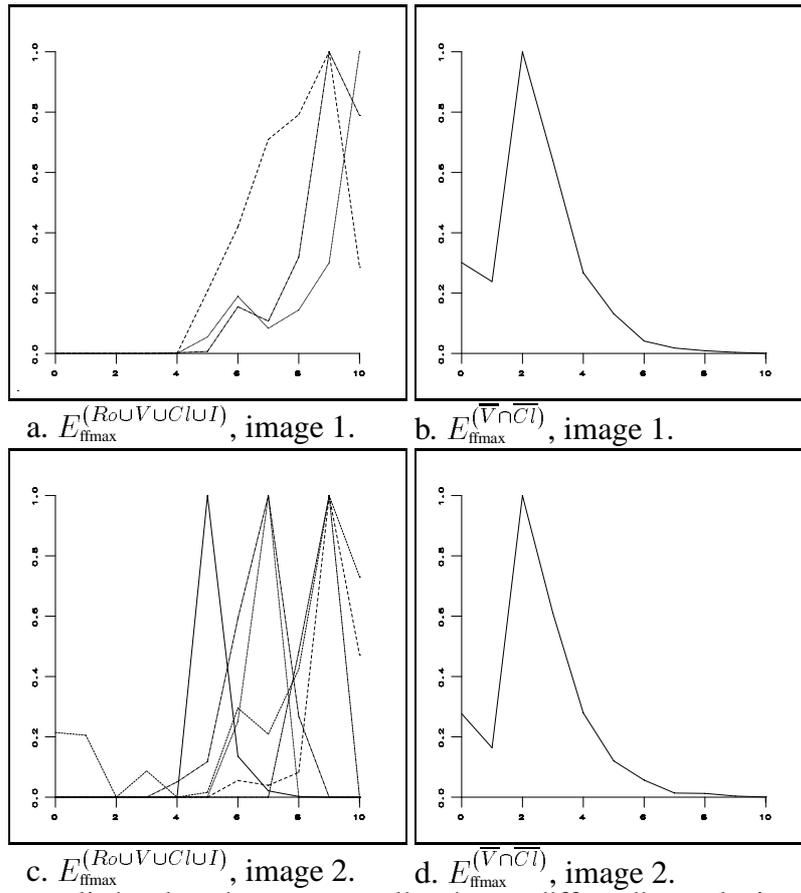
zone	min	max	pop.	moy.	media.	ecart-ty.	var.	$\gamma$	ske.	kurt.
Image	19	22281	950453	433	393	248	61627	0.57	10.97	405.82
forêt										
fo.1	55	1033	17719	407.89	398.50	132	17472	0.32	0.43	3.17
fo.2	53	1272	2464	479	468	157	24760	0.33	0.57	3.84
fo.3	59	2822	13648	391	372	148.41	22024	0.38	1.36	12.82
fo.4	59	1799	5716	426	409	148	22081	0.35	0.80	4.95
ville champ										
vil.1	78	15995	5132	716	512	896	804343	1.25	7.84	87.92
vil.2	193	2260	683	963	935	355	126397	0.37	0.69	3.75
vil.3	92	4297	920	1032	781	707	500546	0.69	1.42	4.728
vil.4	70	7643	1516	669	491	670	449864	1.00	5.04	38.631
vil.5	156	3793	286	1355	1226	838	703534	0.62	0.71	2.707
vil.6	167	2025	504	863.37	848	326	106700	0.38	0.49	3.263
vil.7	97	5142	1474	810.46	572	647	419231	0.79	2.10	8.68
vil.8	146	3376	674	972.41	880	555	309013	0.57	1.17	4.62

visible ou avec peine sur l'image radar. Aussi, comment choisir les échantillons représentatifs? De plus, puisque notre mesure de confiance est à l'origine associée à une route toute entière en tant que chaîne de segments et non à des pixels, ne faut-il pas considérer chaque route comme un échantillon, ce qui n'offre qu'un nombre très limité d'échantillons? Nous avons donc préféré étudier les indices de confiance  $\Delta U$  associés aux routes détectées afin de voir à partir de quelle valeur les routes détectées sont fiables. Comme déjà mentionné précédemment, l'expérience montre que lorsque  $\Delta U$  est supérieur à 0,3, la chaîne de segments correspond souvent à une route existant en réalité. Nous proposons donc la fonction de masse  $m_{\text{route}}$  indiquée sur la figure 8.8. Un raisonnement similaire est effectué pour définir les fonctions de masse des opérateurs "lignes brillantes" et "fleuve" (cf. tableau 8.5). Pour ces trois opérateurs, la difficulté à définir des échantillons représentatifs et en nombre suffisant nous a amenés à une étude empirique des réponses sur les structures détectées.

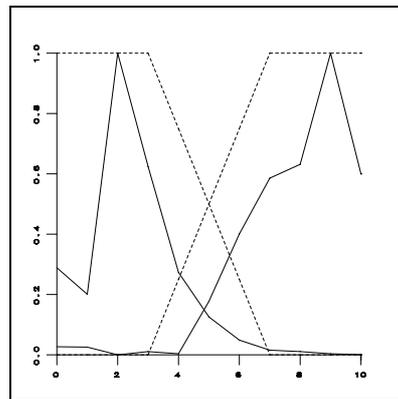
Le tableau 8.5 et la figure 8.9 résume les fonctions de masse des opérateurs utilisés dans notre application.

### **c. Remarques sur le choix des fonctions de masse**

Le choix des éléments focaux et des fonctions de masse a été essentiellement effectué de façon supervisée. La définition même des opérateurs permet en effet de prendre en compte par des raisonnements simples la nature de l'imprécision dont ils vont être entachés, et donc les classes qu'ils seront capables ou pas de distinguer. Nous exploitons donc notre



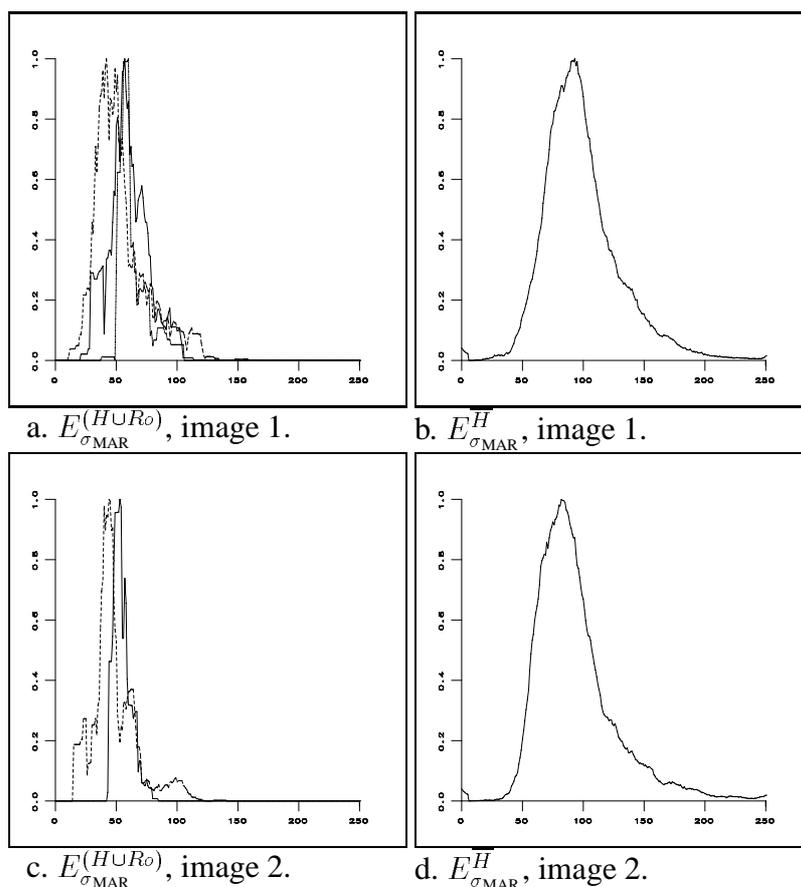
Fréquences normalisées des réponses pour l'opérateur "ffmax" sur plusieurs échantillons représentant ses éléments focaux ( $Ro \cup I \cup Cl \cup V$ ) à gauche et ( $\bar{V} \cap \bar{Cl}$ ) à droite, sur les deux images.



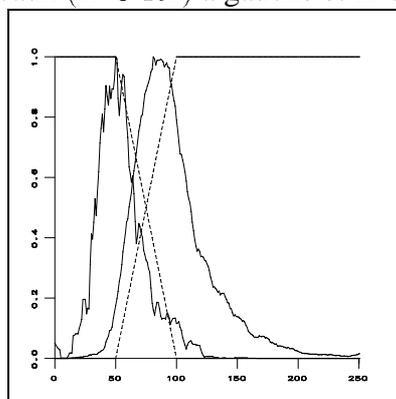
e. Fréquences normalisées sur l'ensemble des échantillons des deux images pour ( $Ro \cup I \cup Cl \cup V$ ) et ( $\bar{V} \cap \bar{Cl}$ ), et fonctions de masse trapézoïdales déduites  $m_{\text{ffmax}}(Ro \cup I \cup Cl \cup V)$  et  $m_{\text{ffmax}}(\bar{V} \cap \bar{Cl})$  en pointillés

FIG. 8.5 – Apprentissage pour l'opérateur "ffmax"

connaissance des informations qui peuvent être délivrées par chaque opérateur. Nous défendons le point de vue que dans une application comme la nôtre, qui vise à l'interprétation



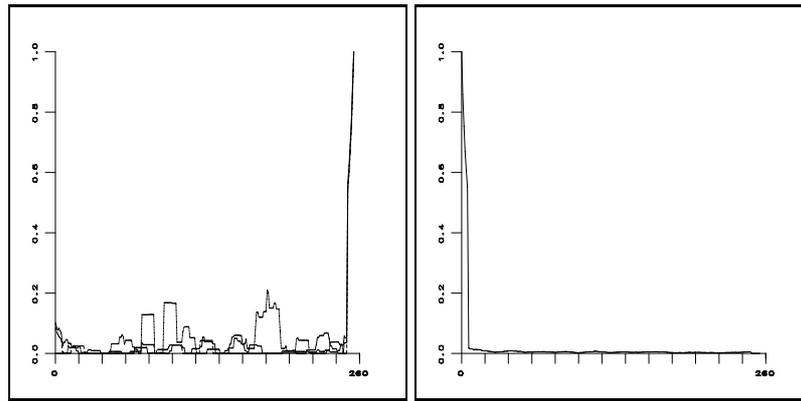
Fréquences normalisées des réponses pour l'opérateur " $\sigma_{MAR}$ " sur plusieurs échantillons représentant ses éléments focaux ( $H \cup Ro$ ) à gauche et  $\bar{H}$  à droite, sur les deux images



e. Fréquences normalisées sur l'ensemble des échantillons des deux images pour ( $H \cup Ro$ ) et  $\bar{H}$ , et fonctions de masse trapézoïdales déduites  $m_{\sigma_{MAR}}(H \cup Ro)$  et  $m_{\sigma_{MAR}}(\bar{H})$  en pointillés.

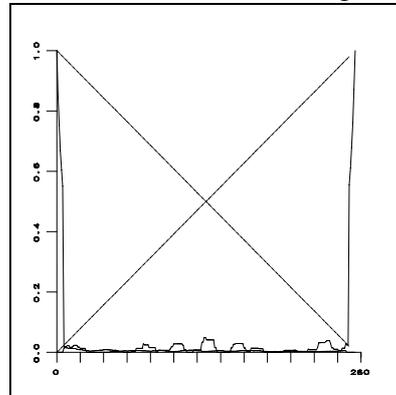
FIG. 8.6 – Apprentissage pour l'opérateur " $\sigma_{MAR}$ "

automatique des images radar, cette étape de modélisation est parfaitement justifiée. Elle ne s'effectue qu'une seule fois et permet ensuite le traitement de toutes les images. Cette supervision ne pose pas de problème lorsque le nombre de classes est relativement limité



a.  $E_{\text{échos forts}}^{(I \cup V \cup Ro)}$ , image 1.      b.  $E_{\text{échos forts}}^{\bar{I}}$ , image 1.

Fréquences normalisées des réponses pour l'opérateur "échos forts" sur plusieurs échantillons représentant ses éléments focaux  $I \cup V \cup Ro$  à gauche et  $\bar{I}$  à droite.



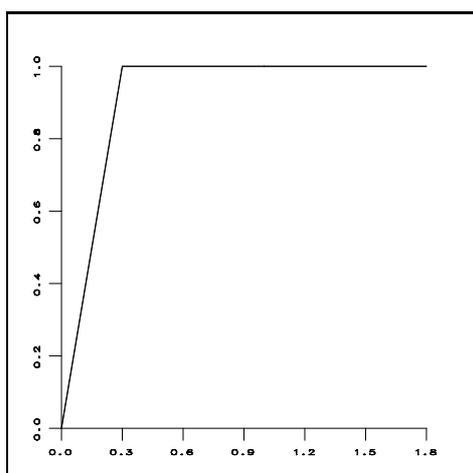
c. Fréquences normalisées sur l'ensemble des échantillons des deux images pour  $(I \cup V \cup Ro)$  et  $\bar{I}$ , et fonctions de masse trapézoïdales déduites  $m_{\text{échos forts}}(I \cup V \cup Ro)$  et  $m_{\text{échos forts}}(\bar{I})$  en pointillés.

FIG. 8.7 – Apprentissage pour l'opérateur "échos forts"

TAB. 8.5 – Opérateurs et éléments focaux

Opérateurs	Eléments focaux et fonctions			
	élément focal	fonction	élément focal	fonction
"lignes brillantes"	$Re$	$g_1 : a = 0 ; b = 0,2$	$\overline{Re}$	$g_2 : a = 0 ; b = 0,2$
"routes"	$Ro$	$g_1 : a = 0 ; b = 0,3$	$\overline{Ro}$	$g_2 : a = 0 ; b = 0,3$
"fleuves"	$Fl$	$f_1$	$\overline{Fl}$	$f_2$
"échos forts"	$Ro \cup V \cup I$	$f_1$	$\bar{I}$	$f_2$
"ffmax"	$Ro \cup V \cup I \cup Cl$	$g_1 : a = 3 ; b = 7$	$\overline{V \cap Cl}$	$g_2 : a = 3 ; b = 7$
" $\sigma_{MAR}$ "	$Ro \cup H$	$g_2 : a = 50 ; b = 100$	$\overline{H}$	$g_1 : a = 50 ; b = 100$

[Bloc-96b]. En revanche, lorsque le problème devient plus complexe, notamment lorsque le nombre de classes n'est pas fixé au préalable et va dépendre des capacités des différentes sources à discriminer les classes, des solutions plus automatiques doivent être développées.



Valeur de la fonction de masse  $m_{\text{routes}}(Ro)$  en fonction des mesures de confiances de l'opérateur "routes", avec  $m_{\text{routes}}(\overline{Ro}) = 1 - m_{\text{routes}}(Ro)$ .

FIG. 8.8 – Fonction de masse pour l'opérateur "routes"

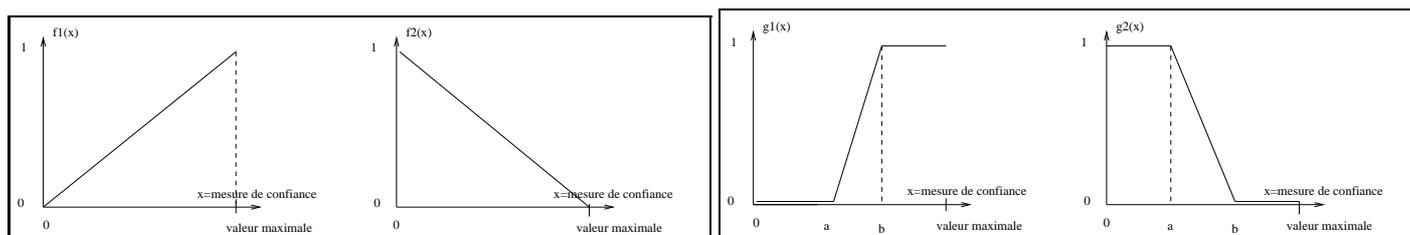


FIG. 8.9 – Formes des fonctions de masses utilisées :  $f_1$ ,  $f_2$ , et  $g_1$ ,  $g_2$  définies par les paramètres  $a$  et  $b$  (seuils bas et haut)

Une solution pour la classification des cultures est proposée dans [LeHe-97]. Elle consiste à définir les classes de la fusion comme les intersections non vides des classes discriminées par chaque capteur (ou opérateur) séparément. Dans notre cas, cette solution amènerait à considérer un trop grand nombre de classes (les classes *route dans urbain dense*, *route dans zone industrielle*, *urbain dense et zone industrielle*, etc.) qui ne sont pas pour nous de nouvelles classes sémantiques mais résultent justement de la très forte imprécision dans la localisation des réponses des opérateurs.

Le choix simpliste des fonctions de masse appelle également des commentaires. En toute rigueur, nous pourrions déduire de l'étude statistique des formes plus fines pour les fonctions de masse. En réalité, ce modèle très simple fournit déjà des résultats globalement satisfaisants. Cela s'explique par le comportement relativement binaire des opérateurs initialement dédiés à la détection d'un objet particulier. Par ailleurs, pour simples que soient les fonctions de masse, les zones de transition des formes trapézoïdales permettent que les paramètres choisis soient relativement approximatifs. Là encore, des solutions pour automatiser l'étape de définition des fonctions de masse étant donné un nombre de classes existent et permettraient d'automatiser en partie le choix des fonctions.

Nous montrons à titre indicatif le résultat d'une méthode d'estimation automatique des

fonctions d'appartenance à partir des modes de l'histogramme d'une image [Bijn-97] [Bloc-97b]. Le nombre de classes étant indiqué par l'utilisateur et la forme des fonctions étant choisie trapézoïdale, un coût est défini, mesurant une distance entre l'histogramme et son approximation par les fonctions d'appartenance. Les paramètres sont ensuite choisis de façon à minimiser ce coût en utilisant un recuit simulé. Lorsque des modes suffisamment marqués de l'histogramme correspondent aux classes définies, la méthode donne de bons résultats (fig. 8.10).

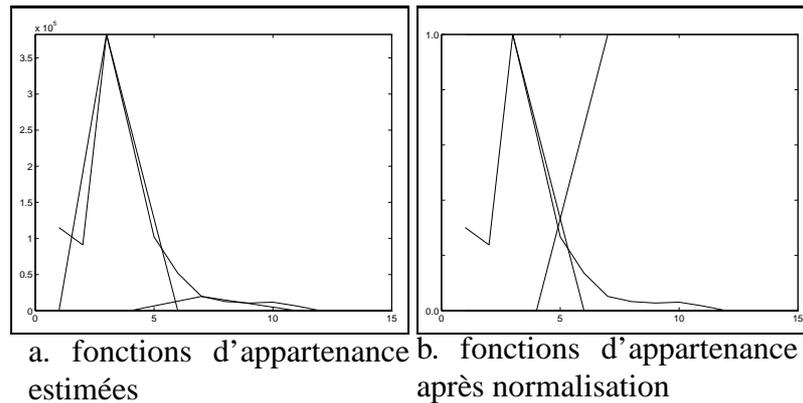


FIG. 8.10 – Apprentissage automatique pour l'opérateur "ffmax" (à comparer avec la figure 8.6)

### 8.3.3 Combinaison

Comme nous l'avons dit précédemment, une fois les fonctions de masse des différentes sources définies, la combinaison est effectuée en appliquant la règle orthogonale de Dempster - Shafer. Cette étape laisse donc peu de marge de manœuvre et appelle par conséquent peu de commentaires, si ce n'est le problème déjà évoqué de la normalisation lors de la fusion de deux sources. Nous allons montrer sur un exemple que la normalisation conduit à des résultats indésirables dans notre contexte où les classes considérées ne sont pas exhaustives. Cela nous amènera naturellement à l'introduction de la classe de rejet  $C_o$ .

Prenons l'exemple de la fusion des opérateurs " $\sigma_{MAR}$ " (dont la fonction de masse est notée  $m_\sigma$ ) et "fleuve" (notée  $m_f$ ). Considérons une région pour laquelle :

$$m_\sigma(H) = x, m_\sigma(Fl) = 1 - x, m_\sigma(A) = 0 \text{ si } A \notin \{H, Fl\}$$

$$m_f(Fl) = 0, m_f(\overline{Fl}) = 1, m_f(A) = 0 \text{ si } A \notin \{Fl, \overline{Fl}\}$$

En combinant les informations des deux sources, nous obtenons  $m(H) = 1 \forall x \neq 0$ . Ainsi, même si la masse de l'hypothèse  $H$  est arbitrairement faible au départ, après combinaison elle sera égale à 1. Cette situation n'est pas souhaitable puisque l'hypothèse de départ est en réalité très peu fiable. Plus généralement, l'utilisation de la normalisation est très controversée et a donné naissance à de nombreux exemples où elle conduit à une situation incohérente [Yage-83] [Yage-85] [Dubo-88] [Smet-90]. En fait, dans notre cas, cette

situation apparaît uniquement parce que l'hypothèse "monde fermé" de la normalisation est particulièrement injustifiée. Il est clair en effet que les hypothèses que nous considérons ne sont pas exhaustives. Nous choisissons donc de tenir compte du conflit en le sauvegardant dans la masse de l'hypothèse vide (ici le conflit vaut  $1 - x$ , donc est élevé si  $x$  est faible), ce qui nous permet de définir naturellement la classe de rejet [Dubo-82] [Yage-83] [Oblo-85].

Nous détaillons ici l'évolution de la fonction de masse résultant des combinaisons au fur et à mesure de l'ajout des opérateurs. Lorsque les différentes sources sont fusionnées, leurs informations se combinent pour discriminer de plus en plus précisément les classes. Dans le cas optimal, à la fin de la combinaison, toutes les hypothèses simples sont discriminées. Nous montrons dans le contexte de notre application comment évoluent les éléments focaux au fur et à mesure de l'introduction des informations. Comme la règle de fusion est associative et commutative, l'ordre donné est arbitraire et n'a aucune influence sur les éléments focaux et le résultat obtenu en fin de combinaison.

Dans les tableaux ci-dessous, les éléments focaux de l'opérateur  $O_n$  combiné à une étape donnée sont indiqués en colonne, et les éléments focaux, résultats des combinaisons effectuées antérieurement et représentant l'opérateur  $O_{1...(n-1)}$ , en ligne. La case à la ligne  $i$  et colonne  $j$  du tableau indique les éléments en commun à l'élément focal de la ligne  $i$  de l'opérateur  $O_n$ , et de l'élément focal de la colonne  $j$  de  $O_{1...(n-1)}$ . Ce sont ces éléments (les cases non vides du tableau) qui constitueront les nouveaux éléments focaux en fin de fusion, donc qui seront les éléments focaux de l'opérateur  $O_{1...n}$  à l'étape suivante. Le signe  $\oplus$  symbolise la fusion entre deux opérateurs

$O_1 \setminus O_2$	<i>Re</i>	$\overline{Re}$
<i>Ro</i>	$\emptyset$	<i>Ro</i>
$\overline{Ro}$	<i>Re</i>	$\overline{Ro \cap Re}$

Étape 1. lignes brillantes $\oplus$ route

$O_4 \setminus O_{123}$	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	$\overline{Ro \cap Re \cap Fl}$
$Ro \cup V \cup I$	<i>Ro</i>	$\emptyset$	$\emptyset$	$V \cup I$
$\overline{I}$	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	$H \cup V \cup Cl$

Étape3. (lignes brillantes $\oplus$ route $\oplus$ fleuve) $\oplus$ échos forts

$O_3 \setminus O_{12}$	<i>Ro</i>	<i>Re</i>	$\overline{Ro \cap Re}$
<i>Fl</i>	$\emptyset$	$\emptyset$	<i>Fl</i>
$\overline{Fl}$	<i>Ro</i>	<i>Re</i>	$\overline{Ro \cap Re \cap Fl}$

Étape 2. (lignes brillantes $\oplus$ route) $\oplus$ fleuve

$O_5 \setminus O_{1234}$	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	$V \cup I$	$H \cup V \cup Cl$
$Ro \cup V \cup I \cup Cl$	<i>Ro</i>	$\emptyset$	$\emptyset$	$V \cup I$	$V \cup Cl$
$\overline{V \cap Cl}$	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	<i>I</i>	<i>H</i>

Étape 4. (lignes brill. $\oplus$ route $\oplus$ fleuve $\oplus$ échos forts) $\oplus$ ffmax

$O_6 \setminus O_{12345}$	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	<i>I</i>	<i>H</i>	$V \cup I$	$V \cup Cl$
$Ro \cup H$	<i>Ro</i>	$\emptyset$	$\emptyset$	$\emptyset$	<i>H</i>	$\emptyset$	$\emptyset$
$\overline{H}$	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	<i>I</i>	$\emptyset$	$V \cup I$	$V \cup Cl$

Étape 5. (lignes brill. $\oplus$ route $\oplus$ fleuve $\oplus$ échos forts $\oplus$ ffmax) $\oplus\sigma_{MAR}$

Éléments focaux finals	<i>Ro</i>	<i>Re</i>	<i>Fl</i>	<i>I</i>	<i>H</i>	$V \cup I$	$V \cup Cl$
------------------------	-----------	-----------	-----------	----------	----------	------------	-------------

Ces tableaux de combinaison appellent plusieurs remarques. Tout d'abord, on constate que certaines hypothèses simples apparaissent comme éléments focaux au fur et à mesure des combinaisons alors qu'elles ne sont jamais détectées seules (c'est le cas de *I* et *H* en particulier). D'autre part, les opérateurs utilisés permettent de lever presque toutes les ambiguïtés entre classes puisqu'il ne reste presque plus que des hypothèses simples en fin de combinaison. Ainsi, pour les classes *Ro*, *Re*, *Fl*, et *H* qui ne sont contenues dans aucun

autre élément focal, la plausibilité et la crédibilité sont égales et nous retrouvons une probabilité bayésienne.

Lorsque toutes les sources ont été combinées, nous repassons à des probabilités en appliquant la transformation pignistique (équation 8.1 du §8.2.3) avec de plus  $BetP(\emptyset) = m(\emptyset)$ . Dans le cas d'une hypothèse simple contenue dans aucun autre élément focal, la probabilité pignistique est égale à la masse. Dans les autres cas, les masses des hypothèses composées sont équiréparties sur les hypothèses simples qui les constituent. Le tableau 8.6 donne ces probabilités en fonction de la masse.

TAB. 8.6 – Transformation pignistique

	<i>Re</i>	<i>Ro</i>	<i>Fl</i>	<i>H</i>	<i>V</i>	<i>I</i>	<i>Cl</i>
<i>BetP</i>	$m(Re)$	$m(Ro)$	$m(Fl)$	$m(H)$	$\frac{m(V \cup I) + m(V \cup Cl)}{2}$	$\frac{m(V \cup I)}{2} + m(I)$	$\frac{m(V \cup Cl)}{2}$

Pour finir, remarquons que dans la théorie des croyances, l'opérateur de fusion (la somme orthogonale de Dempster-Shafer) est toujours conjonctif (quelles que soient les valeurs des masses). Il n'y a donc aucune marge de manœuvre à ce niveau pour l'utilisateur de la théorie des croyances (même si d'autres opérateurs ont ensuite été proposés [Smet-97]). Aussi, toute l'imprécision sur les données doit être introduite au niveau de la modélisation et en particulier dans le choix des éléments focaux.

### 8.3.4 Avantages de la théorie des croyances

Nous justifions dans ce paragraphe notre choix de la théorie des croyances pour la fusion des réponses de détecteurs dans l'interprétation mono-source d'une image.

L'intérêt majeur à nos yeux de la théorie des croyances est de prendre en compte les hypothèses composées, et donc l'ignorance d'une source quant à la discrimination exacte des classes. Le seul équivalent bayésien consiste à répartir le degré de croyance de façon équiprobable sur les hypothèses simples. Se faisant, on hypothèque en réalité d'autant la croyance qui devrait revenir à la "bonne" hypothèse de l'hypothèse composée. Cet avantage nous paraît particulièrement utile pour l'interprétation d'images où les sources sont rarement capables de discriminer exactement toutes les classes. Pour montrer comment les résultats obtenus diffèrent par rapport à un contexte bayésien, considérons l'exemple simple suivant, inspiré des opérateurs dont nous disposons.

Considérons deux opérateurs  $O_1$  et  $O_2$ , et les classes  $V, I, Cl, Ro$  et  $R$  ( $R$  pour la classe *reste*). Supposons que  $O_1$  soit capable de distinguer la classe  $(V \cup Cl)$  contre les autres classes, et  $O_2$ ,  $(Ro \cup I \cup V)$  contre  $(Cl \cup R)$ . Nous pouvons exprimer cela dans le cadre de la théorie de l'évidence par :

$$m_1(V \cup Cl) = x, m_1(I \cup R \cup Ro) = 1 - x, \text{ et } m_1(A) = 0 \text{ si } A \notin \{V \cup Cl, I \cup R \cup Ro\}$$

$$m_2(Ro \cup I \cup V) = y, m_2(Cl \cup R) = 1 - y, \text{ et } m_2(A) = 0 \text{ si } A \notin \{Ro \cup I \cup V, Cl \cup R\}$$

Dans le cadre bayésien, si nous supposons équiprobables les hypothèses simples qu'un opérateur ne peut discriminer :

$$p_1(V) = p_1(Cl) = \frac{x}{2} \text{ et } p_1(I) = p_1(R) = p_1(Ro) = \frac{1-x}{3}$$

$$p_2(V) = p_2(I) = p_2(Ro) = \frac{y}{3} \text{ et } p_2(Cl) = p_2(R) = \frac{1-y}{2}$$

Les expressions des probabilités pignistiques et bayésiennes obtenues après fusion (sous hypothèse d'indépendance des sources) sont données dans le tableau 8.7.

TAB. 8.7 – Probabilités pignistiques et bayésiennes

	V	Cl	I	Ro	R
$BetP$	$xy$	$x(1-y)$	$\frac{(1-x)y}{2}$	$\frac{(1-x)y}{2}$	$(1-x)(1-y)$
$P_{bay} \propto$	$\frac{xy}{6}$	$\frac{x(1-y)}{4}$	$\frac{(1-x)y}{9}$	$\frac{(1-x)y}{9}$	$\frac{(1-x)(1-y)}{6}$

Les décisions prises par le maximum de probabilités dans les deux contextes sont indiquées sur la figure 8.11 en fonction des valeurs de  $x$  (en ligne) et  $y$  (en colonne). On constate la différence des domaines obtenus. Comme prévu, la théorie des croyances donne priorité aux classes communes des hypothèses composées, à savoir *ville* et *reste*, sur lesquelles la masse globale est susceptible de se reporter, contrairement à un cadre bayésien.

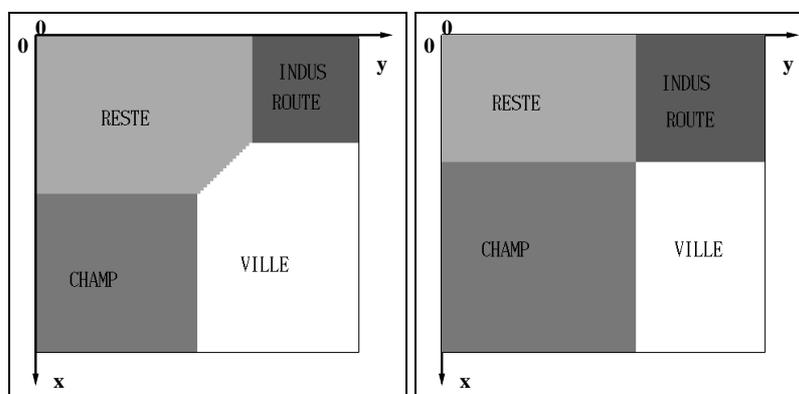


FIG. 8.11 – Décisions données par le maximum des probabilités selon la probabilité pignistique après fusion par la théorie de l'évidence (à gauche) et selon la probabilité bayésienne (à droite)

Pour conclure, disons que la théorie des croyances représente pour nous une solution très appropriée pour fusionner les réponses des opérateurs. Nous avons vu avec l'exemple précédent la plus grande souplesse de cette théorie comparativement aux probabilités. D'autres choix auraient néanmoins pu être faits, comme par exemple l'utilisation des ensembles flous et de la batterie d'opérateurs de fusion qui les accompagne [Bloc-96]. L'effort de modélisation aurait alors porté non plus sur le choix des fonctions de masse, mais sur celui des

opérateurs de fusion proprement dits. Dempster-Shafer nous paraît plus adapté à notre application en intégrant dans le choix des éléments focaux l'imprécision des opérateurs, alors que les ensembles flous portent plus sur les relations entre eux. Nous pensons également que des résultats proches pourraient être obtenus à partir d'un système à base de règles sur les détections séparées des différents objets. Mais il faudrait alors définir des priorités entre les classes sur toutes les zones de conflit, ce qui nous amènerait là encore à modéliser le comportement des opérateurs pour la détection des classes.

### 8.3.5 Aspects pratiques

Nous donnons dans cette section quelques détails pratiques sur l'implantation de la méthode de fusion.

Nous avons  $K = 6$  opérateurs et  $N = 7$  classes sémantiques, donc un total de  $2^N = 128$  hypothèses à considérer en comptant l'hypothèse vide correspondant à la classe de rejet  $C_o$ . Le nombre d'hypothèses et d'opérateurs interdit toute tabulation des valeurs. En effet, supposons que les réponses de chaque opérateur soient ramenées sur 256 valeurs (i.e codées sur 8 bits), il y aurait alors  $256^6$  combinaisons possibles donnant lieu à une valeur de la fonction de masse pour chacune des 128 hypothèses, soit  $3,6 \cdot 10^{10}$  méga-octets à stocker. En fait, nous avons vu que dans l'application aux images radar, telle qu'elle est réalisée actuellement, toutes les hypothèses ne sont pas des éléments focaux, et nous pourrions utiliser seulement les éléments des tableaux de la section 8.3.3. Cette solution n'est pas satisfaisante si nous voulons conserver à la méthode sa généralité et en particulier changer les éléments focaux des opérateurs ou ajouter un nouvel opérateur dont les éléments focaux n'ont pas été envisagés jusqu'à maintenant. Nous avons donc décidé de conserver les 128 hypothèses puisqu'elles sont toutes susceptibles d'être des éléments focaux. Ce choix est primordial pour conserver à la méthode un aspect général et modulaire.

La structure que nous avons définie pour chaque opérateur est la suivante. Nous conservons dans un fichier le numéro d'étiquetage de chaque région suivi des masses des 128 hypothèses. Ces masses sont calculées pour chaque opérateur comme indiqué dans les sections précédentes. Lorsque deux opérateurs sont fusionnés, le résultat est donné sous le même format : un fichier contenant pour chaque région les masses des 128 hypothèses, résultats de la fusion cette fois-ci. Ainsi, pour l'ajout d'un nouvel opérateur  $O_i$ , il suffit de créer le fichier de masses associé à  $O_i$ , et d'utiliser le fichier de masses résultat de toutes les fusions précédentes. Les fichiers de masse occupent une place relativement importante en mémoire. En effet, si  $L$  est le nombre de régions de l'image à traiter, il faut conserver pour chaque opérateur  $L \times 2^N$  flottants. Néanmoins, on peut détruire les fichiers de masse des opérateurs au fur et à mesure de la fusion et ne conserver que le fichier de masse résultat.

Au niveau des temps de calcul, la fusion entre deux opérateurs prend environ six minutes pour un nombre de régions de l'ordre de 10 000 (c'est le nombre moyen de régions sur une image  $1024 \times 1024$ ), soit en tout une demi-heure pour réaliser l'ensemble de la fusion.

## 8.4 Classification par régularisation markovienne sur le graphe d'adjacence

La fusion des opérateurs par Dempster - Shafer permet d'obtenir une fonction de masse résultat. L'étape de décision a ensuite pour rôle, connaissant cette fonction de masse, d'attribuer une classe d'appartenance à chaque région. Plusieurs critères peuvent être utilisés correspondant à des comportements plus ou moins optimistes. Nous proposons d'introduire dans cette étape de décision une information contextuelle que nous n'avons pas exploitée jusqu'à présent. Le cadre markovien se prête bien à cela au travers du choix de la probabilité a priori (cf. chapitre 3). Comme l'utilisation du cadre bayésien auquel il est lié nécessite de définir pour chaque région des probabilités d'appartenance à chacune des classes, nous utilisons la transformation pignistique. Il nous faut ensuite définir un système de voisinage correspondant aux primitives traitées (ou un graphe, ce qui revient au même) et les fonctions de potentiel des cliques qui lui sont associées (cf. chapitre 3). Si les relations contextuelles introduites sont simples, elles peuvent être définies de façon supervisée. Nous illustrons les principes énoncés ici dans le cadre de notre application.

Avec les opérateurs définis ici, cette étape contextuelle est en fait impérative puisque certaines classes ont exactement les mêmes probabilités après la transformation pignistique ; c'est le cas par exemple pour les classes  $V$  et  $Cl$  lorsqu'aucune information supplémentaire n'a été apportée par les autres sources, puisque l'opérateur "ffmax" n'est a priori et par construction pas capable de distinguer ces deux classes. C'est pourquoi nous proposons d'ajouter une étape contextuelle qui permettra de lever ces ambiguïtés par une analyse des régions voisines.

Le graphe que nous utilisons est le graphe d'adjacence des régions : ainsi les nœuds sont constitués par les régions et les arcs représentent la relation d'adjacence entre deux régions<sup>8</sup>. En associant à chaque nœud une variable aléatoire, nous pouvons définir un champ aléatoire et le supposer a priori markovien (cette hypothèse est là encore justifiée parce que des connaissances locales sont suffisantes pour lever l'ambiguïté sur une région). Sous certaines hypothèses d'indépendance, on peut montrer que le champ a posteriori est également markovien pour le même système de voisinage. Le formalisme est tout a fait comparable à ceux des chapitres 3 et 6, aussi ne le reprenons nous pas en détail ici. L'hypothèse  $\emptyset$  est assimilée à la classe de rejet. L'expression des termes énergétiques est la suivante :

- terme d'attache aux données : il découle directement de la probabilité pignistique :

$$V(C_i) = -\ln(\text{Bet}P(C_i))$$

Les probabilités nulles pour lesquelles le potentiel serait infini sont remplacées par des valeurs très faibles.

- terme a priori : les potentiels des cliques sont définis par un modèle de Potts visant à favoriser les adjacences entre classes de mêmes étiquettes ou d'étiquettes "compatibles",

---

8. La relation d'adjacence est très restrictive et ne permet pas d'exploiter toute l'information contextuelle de l'image. C'est le cas notamment pour les structures de relief dont la fréquence et le parallélisme sont des informations importantes pour discriminer les fausses alarmes. Une version plus élaborée devrait tenir compte de ces propriétés.

et à défavoriser celle entre étiquettes "incompatibles". Les potentiels de cliques d'ordre supérieur ou égal à trois sont nuls. Le potentiel d'une clique  $c = (C_i, C_j)$  d'ordre deux est donné par :

$$V_c(C_i, C_j) = K_l$$

où  $l$  est un indice dépendant de la relation d'adjacence entre les classes. Les contraintes d'adjacence utilisées dans notre contexte sont exprimées dans la matrice du tableau 8.8. Nous avons choisi de distinguer trois situations auxquelles sont associés trois paramètres  $K_l$  différents :

- l'adjacence est favorisée entre deux régions (entre une classe et elle-même mais aussi entre la classe *ville* et la classe *industriel* par exemple) ; cette relation est notée  $\mathcal{A}$ , et correspond au paramètre  $K_{\mathcal{A}}$  négatif ;
- l'adjacence est neutre, notée  $\mathcal{N}$ , acceptée mais non favorisée entre deux régions ; le paramètre correspondant  $K_{\mathcal{N}}$  est nul ;
- l'adjacence est défavorisée entre deux régions, notée  $\mathcal{I}$  (par exemple entre la classe *champ clair* et la classe *industriel* puisque c'est une situation exceptionnelle qui correspond souvent à une mauvaise discrimination entre *ville* et *champ clair*) ;  $K_{\mathcal{I}}$  est positif.

TAB. 8.8 – Matrice d'adjacence :  $\mathcal{A}$  indique que l'adjacence entre deux classes est favorisée,  $\mathcal{I}$  qu'elle est défavorisée, et  $\mathcal{N}$  qu'elle est neutre (ni favorisée, ni défavorisée).

Classes	<i>Re</i>	<i>Ro</i>	<i>Fl</i>	<i>H</i>	<i>V</i>	<i>I</i>	<i>Cl</i>	$\emptyset$
<i>Re</i>	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{I}$	$\mathcal{I}$	$\mathcal{I}$	$\mathcal{N}$
<i>Ro</i>	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{A}$
<i>Fl</i>	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{A}$
<i>H</i>	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{N}$
<i>V</i>	$\mathcal{I}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{N}$
<i>I</i>	$\mathcal{I}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{I}$	$\mathcal{N}$
<i>Cl</i>	$\mathcal{I}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{I}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{N}$
$\emptyset$	$\mathcal{N}$	$\mathcal{A}$	$\mathcal{A}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{N}$	$\mathcal{A}$

On peut également nuancer le modèle en mettant des constantes d'adjacence de valeurs variables pour les différentes classes. Ainsi, comme plusieurs régions ont une probabilité maximale pour la classe de rejet  $C_o$ , on peut contre-balancer l'effet de propagation du modèle de Potts en choisissant une valeur de la constante  $K_{\mathcal{A}}$  moins favorable. En outre, le paramètre de l'adjacence défavorisée  $K_{\mathcal{I}}$  reste dans les mêmes proportions que les autres paramètres pour éviter que des îlots de régions se forment au cours du recuit en créant des barrières énergétiques qu'il ne serait pas possible de franchir. Par ailleurs, pour que les régions qui ne sont pas proches de régions classées *industriel* soient classées *champ clair*, nous avons mis un potentiel négatif pour les cliques d'ordre 1 de cette classe. En effet, notre expérience nous a montré que les grandes villes ou zones urbaines susceptibles donc d'être

classées en urbain dense sont toujours entourées en périphérie de forts réflecteurs qui répondent bien à l'opérateur "échos forts" qui leur est dédié. Par conséquent, les régions pour lesquelles ce critère n'est pas vérifié sont bien souvent des champs de forte radiométrie.

D'un point de vue pratique, un fichier contenant la structure du graphe est créé pour réaliser l'étape contextuelle. Il contient pour chaque région le nombre de régions voisines et les numéros de ces régions. Le recuit simulé avec une température initiale de 5 et une décroissance géométrique de facteur 0.95 nécessite une centaine d'itérations et prend de l'ordre de sept minutes pour environ 10 000 régions (nombre moyen de régions pour une image  $1024 \times 1024$ ).

Pour finir sur l'étape de régularisation, notons que nous avons choisi d'introduire des relations contextuelles dans l'étape de décision par l'intermédiaire d'un champ Markovien et en repassant à une probabilité bayésienne. Une autre solution aurait pu consister à introduire une connaissance spatiale directement dans la définition des fonctions de masses. On pourrait par exemple utiliser une méthode du type de celle de Denœux [Deno-95].

## 8.5 Résultats

Le schéma général de la méthode d'interprétation que nous proposons est présenté dans le cas des images radar sur la figure 8.12.

L'enchaînement des différentes étapes a été effectué sur toutes les images de notre base de tests sans modifications des paramètres pour un capteur fixé (ERS-1, SIR-C/X-SAR, RADARSAT). Seules les classes *mer* et *forêt* sont distinguées l'une de l'autre "manuellement" : la mer est assimilée à la plus grande composante connexe des régions ayant une probabilité de 1 pour la classe *homogène*.

### 8.5.1 Résultats sur des images ERS-1

D'une façon générale, les résultats sont relativement satisfaisants. Le milieu urbain et industriel est bien détecté avec peu de confusions avec les champs ou le relief. Nous pensons qu'une discrimination plus fine que celle des classes *ville* et *industriel* est possible en utilisant de simples critères radiométriques [Goui-96b]. La détection des routes est relativement décevante dans le résultat global et des efforts supplémentaires devraient y être consacrés. Cependant, en l'absence de sources d'informations supplémentaires, il n'est pas sûr que des améliorations puissent être obtenues facilement. Le relief est bien détecté et une étape complémentaire permettrait aisément de supprimer les fausses alarmes (petites structures linéaires n'appartenant pas à une composante de relief). Les dénivellations en bord des fleuves sont également bien détectées. Les résultats concernant la forêt sont inégaux et les paramètres mériteraient une adaptation sur chaque image. Ainsi la forêt de Ligoures ressort bien sur l'image d'Aix, mais la classification est trop grossière sur l'image de Roissy où des structures plus fines sont globalement classées *forêt*. Typiquement, des seuils plus stricts seraient nécessaires sur certaines des images. La classe *champ clair* a été reclassifiée dans la classe de rejet car elle a surtout été utilisée pour discriminer les fausses alarmes en urbain dense. D'autres critères devraient être intégrés pour délimiter les champs.

La légende utilisée est celle du tableau 8.9. La forêt étant une classe donnée à titre indicatif, nous avons laissé les niveaux de gris qui sont proportionnels à la probabilité des régions (du plus foncé, le moins fiable, au plus clair, le plus fiable). Nous ne considérons comme *forêt* pour l'interprétation que les zones les plus fiables. Pour les autres classes thématiques, il ne leur correspond qu'un seul niveau de gris. Pour faciliter la comparaison avec la carte, les noms des villes correspondant aux détections ont été rajoutés manuellement sur les images de résultats. Les zones urbaines peu fiables (faibles probabilités) ont été classées en *banlieue*.

TAB. 8.9 – *Légende des figures*

Classe	Image en niveaux de gris	Image en couleurs
<i>rejet</i>	noir	gris
<i>route</i>	gris + contours blancs	rouge
<i>fleuves</i>	gris plus clair + contours blancs	bleu
<i>mer</i>	gris foncé	bleu
<i>forêt</i>	niveaux de gris	niveaux de vert
<i>relief</i>	blanc	violet
<i>ville</i> (dense)	gris très clair + contours blancs	jaune
<i>industriel</i> (moins dense)	gris clair + contours blancs	orange
<i>banlieue</i> (peu fiable)	gris assez clair + contours blancs	marron

Les estimations qui sont données ici correspondent à une comparaison visuelle avec la carte.

• **Image d'Aix-en-Provence** (fig.8.13) : les résultats sont globalement satisfaisants.

→ *ville, industriel, banlieue* : l'urbain est bien détecté, les petites zones correspondant bien à des villes ou villages sur la carte (tab. 8.10) ;

→ *forêt* : la zone de forêt du Bois de Ligoures est bien détectée (elle apparaît avec une confiance bien plus forte que les autres régions classées *forêt*)

→ *relief* : la montagne du Montaignet apparaît clairement aussi.

• **Image de Lorient** (fig.8.14) : les résultats sont globalement satisfaisants.

→ *ville, industriel, banlieue* : l'urbain est bien détecté, les fausses alarmes dues aux champs brillants ont pu être totalement levées grâce à la classification markovienne contextuelle (tab. 8.10) ;

→ *homogène* (*mer* et *forêt*) : l'estuaire a été classé dans *homogène* avec une très forte confiance (sa taille n'est pas suffisante pour justifier une détection automatique future en classe *mer* sur cette image) ; le fond de *forêt* correspond à des zones relativement homogènes mais englobe le parcellaire ;

→ *route* : la détection des réseaux demande à être améliorée.

• **Image de Roissy** (fig.8.15) : les résultats sont corrects.

→ *ville, industriel, banlieue* : l'urbain est relativement bien détecté sauf l'aéroport très dense sans "points brillants" qui a été classé "champ brillant" et donc apparaît dans la classe de *rejet* (tab. 8.10) ;

→ *route* : les réseaux demanderaient à être connectés et complétés ;

→ *forêt* : le fond *forêt* est effectivement relativement homogène mais devrait être classé plus en détails.

• **Image de Mantes-La-Jolie** (fig.8.16) : les résultats sont globalement satisfaisants.

→ *ville, industriel, banlieue* : l'urbain est relativement bien détecté mais incomplet (tab. 8.10 ; en particulier, Mousseaux sur Seine au milieu de la boucle de la Seine n'est pas détecté) ;

→ *fleuve* : le fleuve est bien détecté mais l'autoroute qui a aussi été détectée très facilement apparaît (ce cas de figure devrait être envisagé dans la suite) ;

→ *route* : les routes sont trop incomplètes ;

→ *forêt* : les bois sont bien détectés (zones les plus claires du fond *forêt*) ;

→ *relief* : les lignes de relief à proximité du fleuve sont justifiées par la dénivellation qui existe.

• **Image de Lelystad** (fig.8.17) : les résultats sont décevants avec plusieurs erreurs, alors que cette image est particulièrement agréable à regarder pour un observateur humain à cause du parcellaire dense.

→ *ville, industriel, banlieue* : l'urbain est mal détecté avec de fausses alarmes dans les zones de parcellaires denses ; cela s'explique par la présence de points brillants isolés (maisons ? outillage particulier entre les champs ?) qui entraîne de fortes réponses de l'opérateur "échos forts" ; les champs clairs alentours sont alors classés définitivement "ville" par le terme contextuel du champ Markovien (tab. 8.10) ;

→ *route* : les réseaux qui sont principalement des canaux sont néanmoins bien détectés dans l'ensemble ;

→ *relief* : les lignes de relief sont en majorité des champs allongés mal interprétés ;

• **Image de Kourou** (fig.8.18) : les résultats sont corrects, avec quelques erreurs cependant, mais les classes thématiques correspondent mal à ces paysages et devraient être affinées.

→ *ville, industriel, banlieue* : les zones urbaines sont en majorité bien détectées, sauf une fausse alarme à la séparation du fleuve en deux bras due à des points brillants (tab. 8.10) ;

→ *relief* : deux bonnes détections (le long du fleuve et la montagne des Pères, mais des fausses alarmes le long du trait de côte) ;

→ *forêt* : les zones de mangrove sont bien classées dans les régions de forêt, mais des classes plus fines seraient nécessaires.

## 8.5.2 Résultat sur des images SIR-C/X-SAR

Là encore, les résultats sont globalement corrects même s'ils sont très en-deçà de ceux que pourrait obtenir un opérateur humain. Nous avons choisi d'illustrer la méthode sur deux images de la même zone (site d'Oberpfaffenhofen en Allemagne) mais à des résolutions différentes. La première (fig. 8.19) est une image produit MGD (résolution d'environ 25m et d'espacement inter-pixels de 12,5m en 3 vues comparable au produit PRI d'ERS-1), et la seconde (fig. 8.21) un produit HRMGD (haute résolution : résolution 10m, espacement

TAB. 8.10 – Résultats pour la classe urbaine (le signe \* indique qu'on a attribué un nom générique à un groupe de villages)

Image	bonnes détections	fausses détections	omissions
Aix	Aix-en-Provence, Les Milles, Lenfant, Luynes, Gardanne, Meyreuil, Panperdu, Les Gervais, Eguilles, Celony 10	2?	
Lorient	Lorient, Lanester, Hennebont, Kervignac, Kerfichant, Caudan, Le Temple, Lochrist* 7		Plessis
Roissy	Villeparisis, Mitry-Mory, Tremblay-en-France Sevrans, Thieux, Mauregard, Gressy, Messy, Claye-Souilly, Tremblay-Vieux-Pays, Les Acacias, Juilly, Le Mesnil-Amelot 13		Nantouillet, Compans, aéroport 3
Mantes-La-Jolie	Mantes-La-Jolie, Rosny sur Seine, Guernes, Limay, Mantes-La-Ville, Dennemont, Follainville, La Roche-Guyon, Vetheuil, Fresneuse, Gasny, Moisson, Sandrancourt, Claudry 14		Mousseaux sur seine, St-Martin-La-Garenne, Méricourt 3
Lelystad	Lelystad, Swifterband, Dronten Observatoire 4	5	
Kourou	Kourou, la zone industrielle, le centre spatial 3	1	

inter-pixel 6,25m et nombre de vues 1) qui couvre une sous-région de la première.

- **Image MGD** : les paramètres utilisés sur les image ERS-1 n'ont pas été modifiés puisque le nombre de vues est le même que sur les images ERS-1 PRI. Nous pensons néanmoins que leur adaptation en tenant compte des spécificités de ce capteur, notamment la différence de longueur d'onde, permettrait d'améliorer les résultats (fig. 8.20). Par souci de clarté, le fleuve et les petites surfaces d'eau sont indiquées en noir entourées par des contours blancs.

- **Image HRMGD** : les paramètres ont été adaptés, notamment pour les routes puisque le nombre de vue est moins important (cf. chapitre 4) et pour l'opérateur  $\sigma_{MAR}$ . Globalement, les résultats sont satisfaisants, mais en l'absence de carte il est difficile d'évaluer la détection

de certaines classes avec certitude (fig. 8.22). De plus, l'urbain est facilement discriminable avec beaucoup moins d'échos forts dispersés dans l'image, comme c'est souvent le cas sur les images ERS-1 (voir l'image d'Aix-en-Provence ou de Lorient par exemple).

### 8.5.3 Résultat sur des images RADARSAT

Nous avons testé la méthode sur l'image RADARSAT d'Amsterdam. Le nombre de vues étant le même que sur les images ERS-1 PRI, nous avons conservé les mêmes paramètres et appliqué l'ensemble de la méthode sans modification, à l'exception de la détection du fleuve qui a été faite de façon supervisée. En effet, la méthode de détection a été appliquée aux résolutions dégradées en blocs de 8 par 8, et 4 par 4 pixels. Les résultats obtenus sont corrects pour l'ensemble des classes sémantiques mais soulignent les problèmes de discrimination entre le réseau hydrographique et routier, surtout lorsqu'il s'agit de canaux comme c'est souvent le cas sur les images des Pays-Bas.

## 8.6 Conclusion

Nous avons montré au cours de ce chapitre que la théorie des croyances était un cadre approprié pour réaliser la fusion d'informations extraites par différents opérateurs dans un cas mono-source. En effet, cette théorie permet de tenir compte de l'incapacité de ces opérateurs à discriminer certaines classes en permettant de considérer des hypothèses composées. Couplée avec une étape contextuelle permettant de lever les ambiguïtés restantes, cette approche a permis d'obtenir des résultats globalement satisfaisants sur un grand nombre d'images traitées. Les différentes classes sémantiques sont en général bien détectées mais un problème subsiste pour la discrimination des réseaux routiers et hydrographiques.

Ce chapitre concrétise notre contribution au problème de l'analyse de scènes radar en présentant un cadre général et modulaire pour l'intégration des réponses des différents détecteurs proposés. Il y a, à notre connaissance, peu d'applications de la théorie de l'évidence de Dempster et Shafer dans ce cadre essentiellement mono-source. Sans prétendre à l'unicité de cette solution, nous avons montré que ce cadre très souple apportait une réponse cohérente et bien adaptée au problème.

A titre de perspective, nous aurions souhaité introduire un niveau hiérarchique supplémentaire qui contrôlerait la cohérence globale de la scène, non plus au niveau des régions de la segmentation mais des objets (routes, forêts, villes...) obtenus. Cette cohérence peut s'envisager sous plusieurs formes : vérification de la présence de routes reliant les villes, raccordement rivière / mer, etc. Néanmoins, le peu d'objets détectés sur une image radar, et par conséquent le faible nombre de relations possibles, rendent peu utile une telle approche, plus appropriée en imagerie aérienne. En revanche, l'introduction d'une carte pour valider automatiquement le résultat de l'interprétation nous paraît une perspective particulièrement prometteuse.

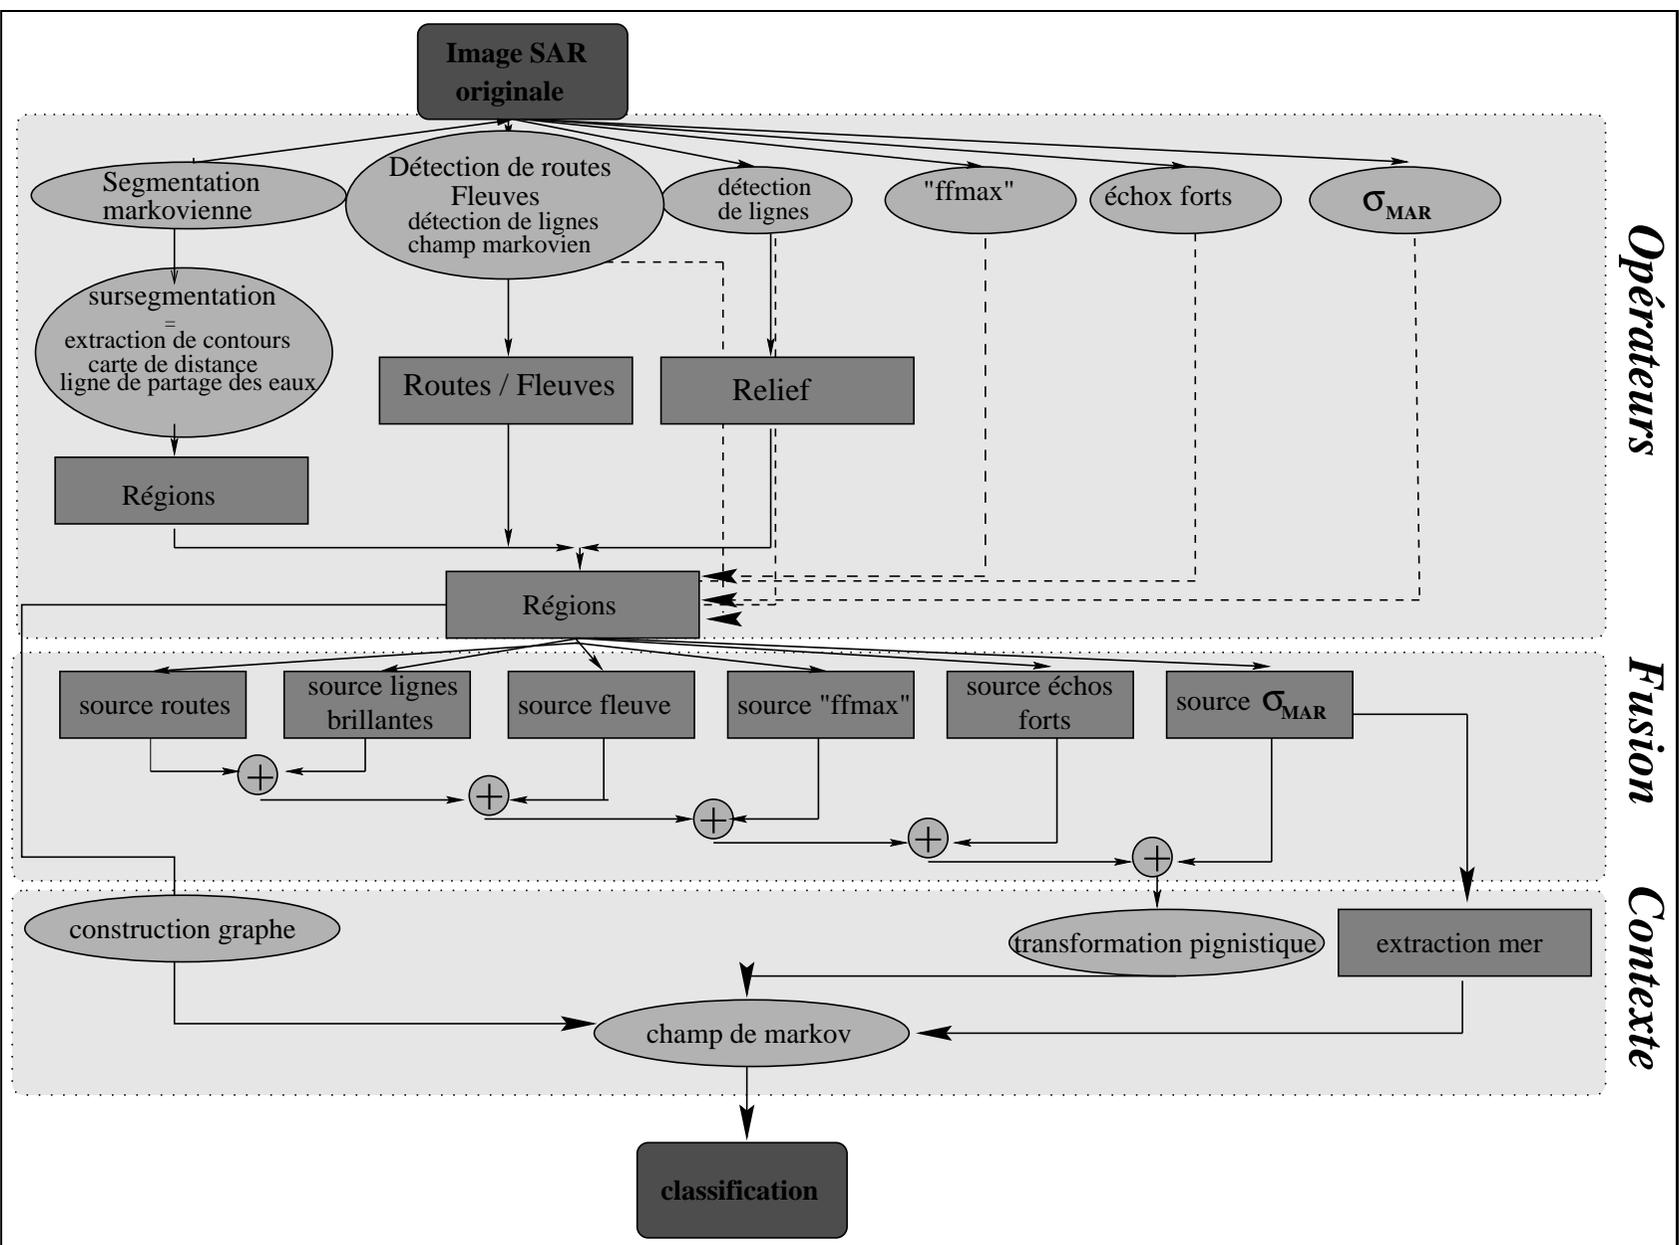


FIG. 8.12 – Schéma général de la méthode

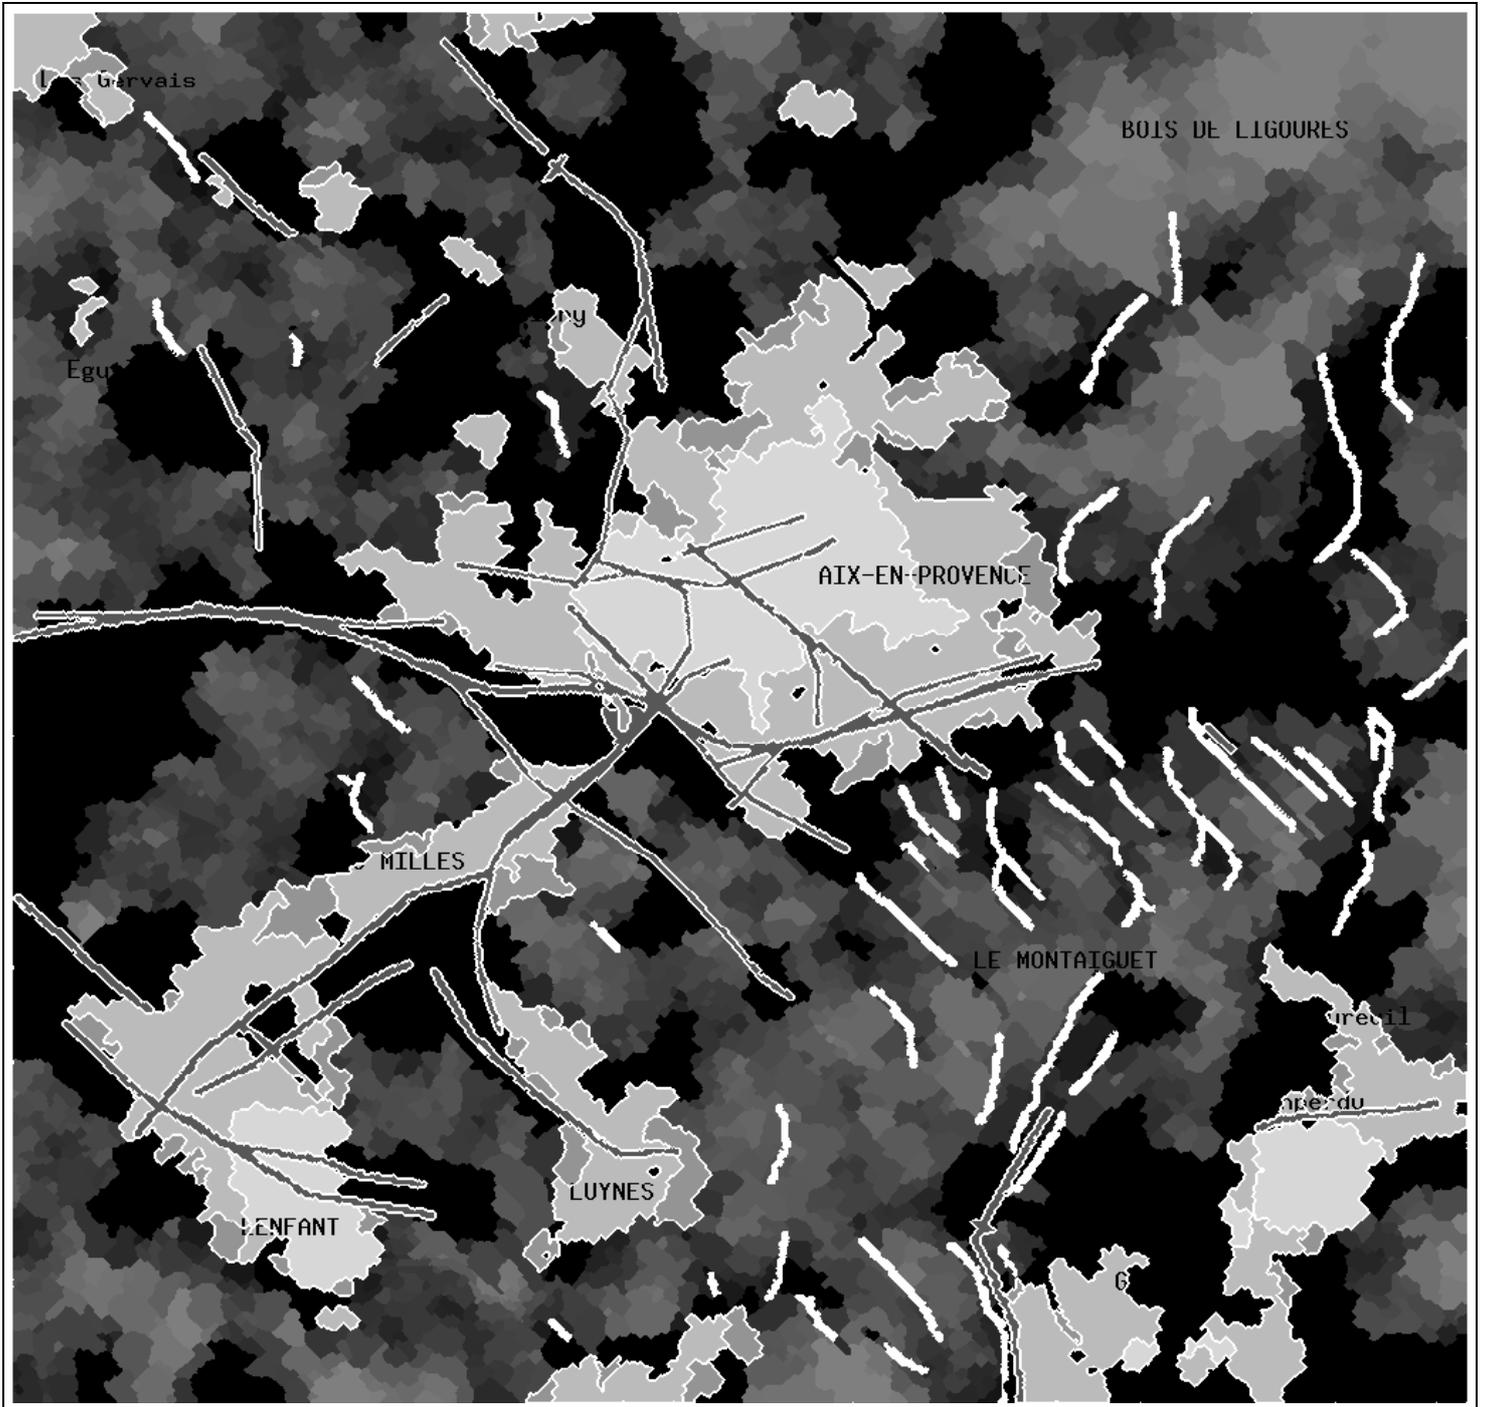


FIG. 8.13 – Résultat de l'interprétation sur Aix-en-Provence (annexe A.5)

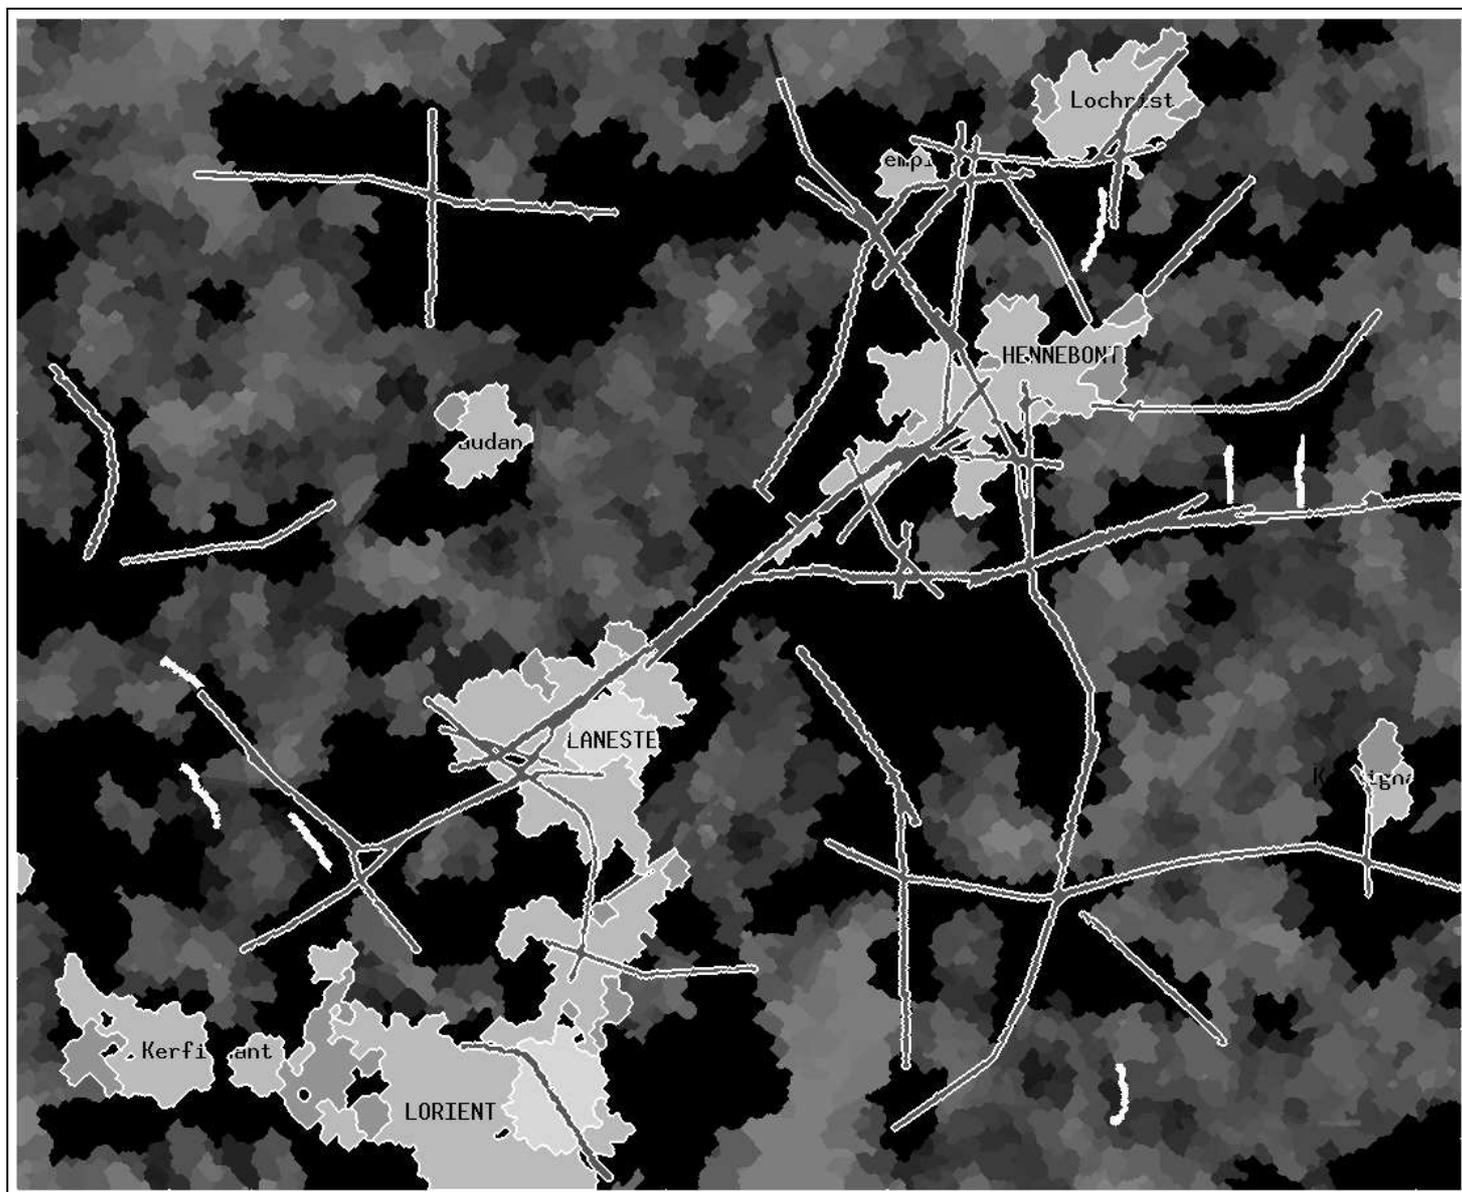


FIG. 8.14 – Résultat de l'interprétation sur Lorient (annexe A.3)

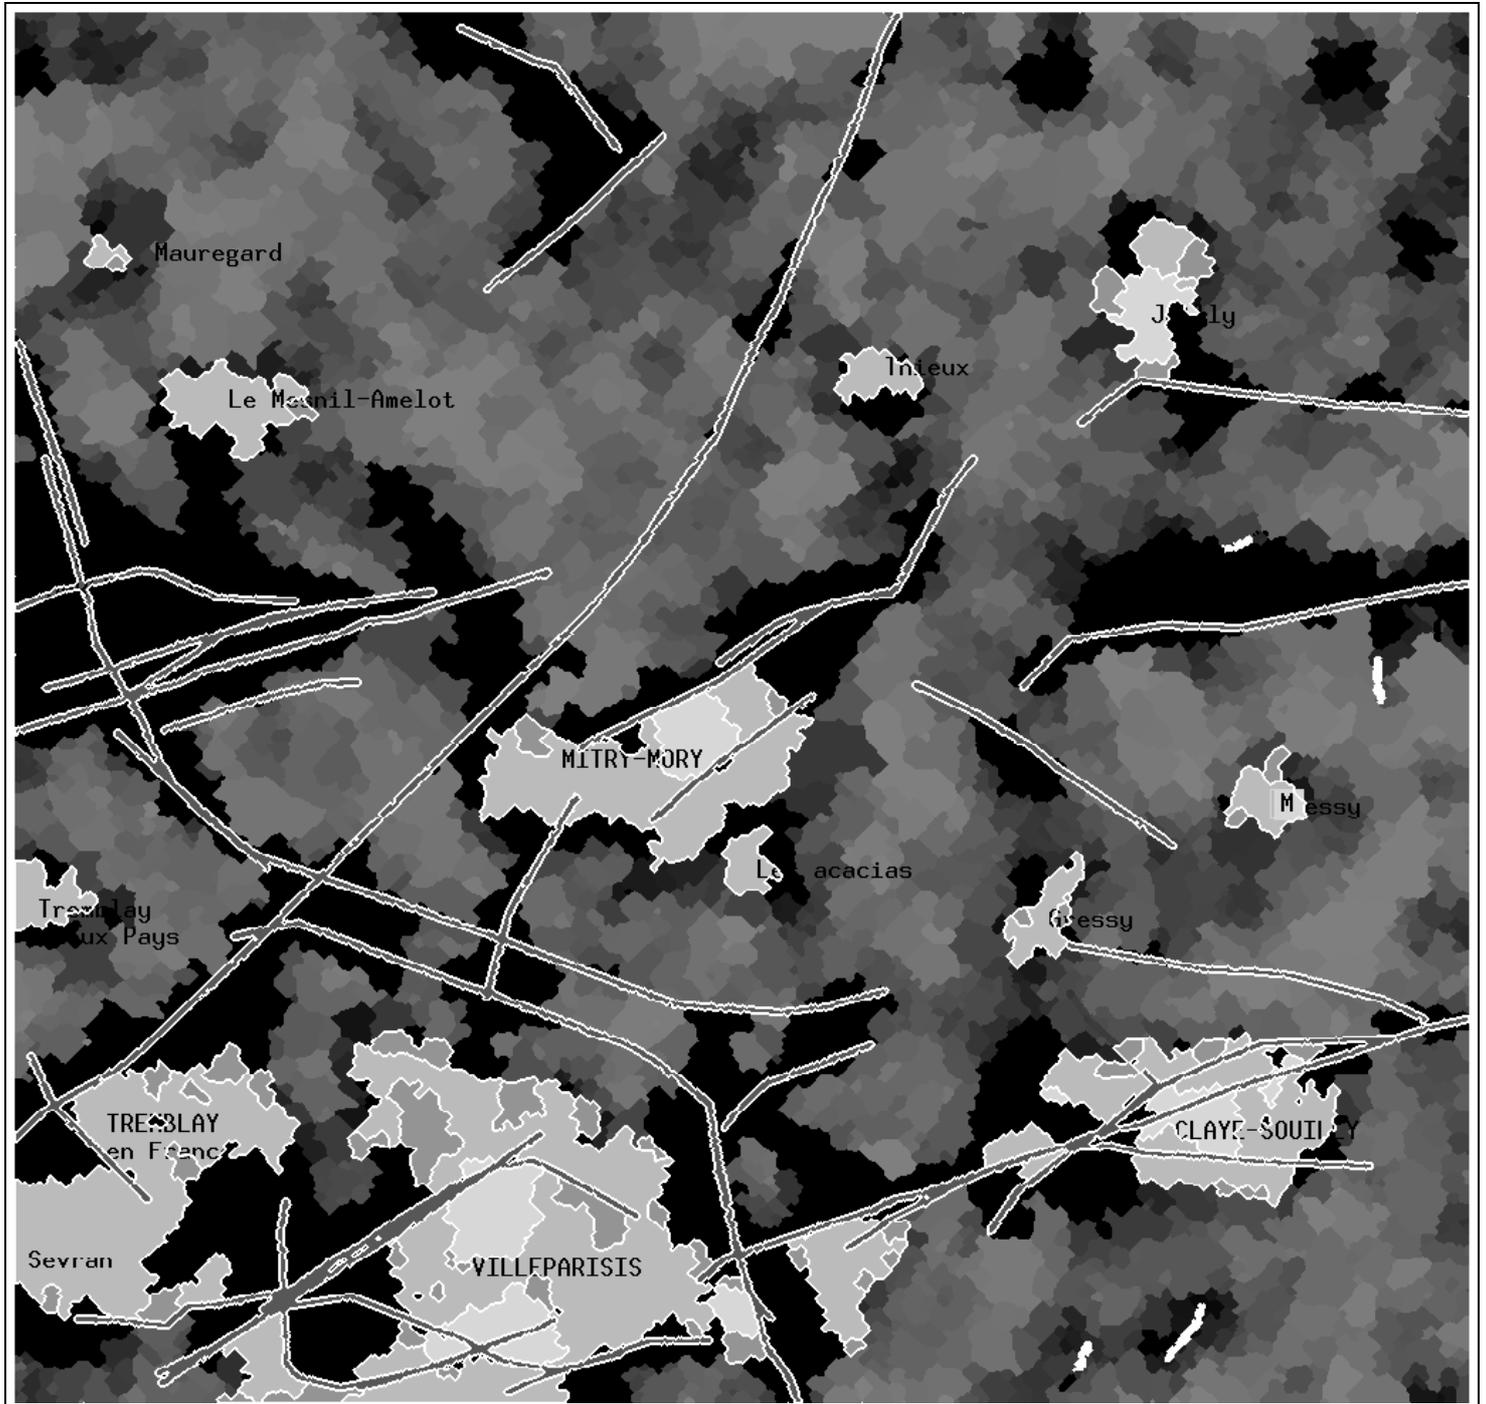


FIG. 8.15 – Résultat de l'interprétation sur Roissy (annexe A.4)

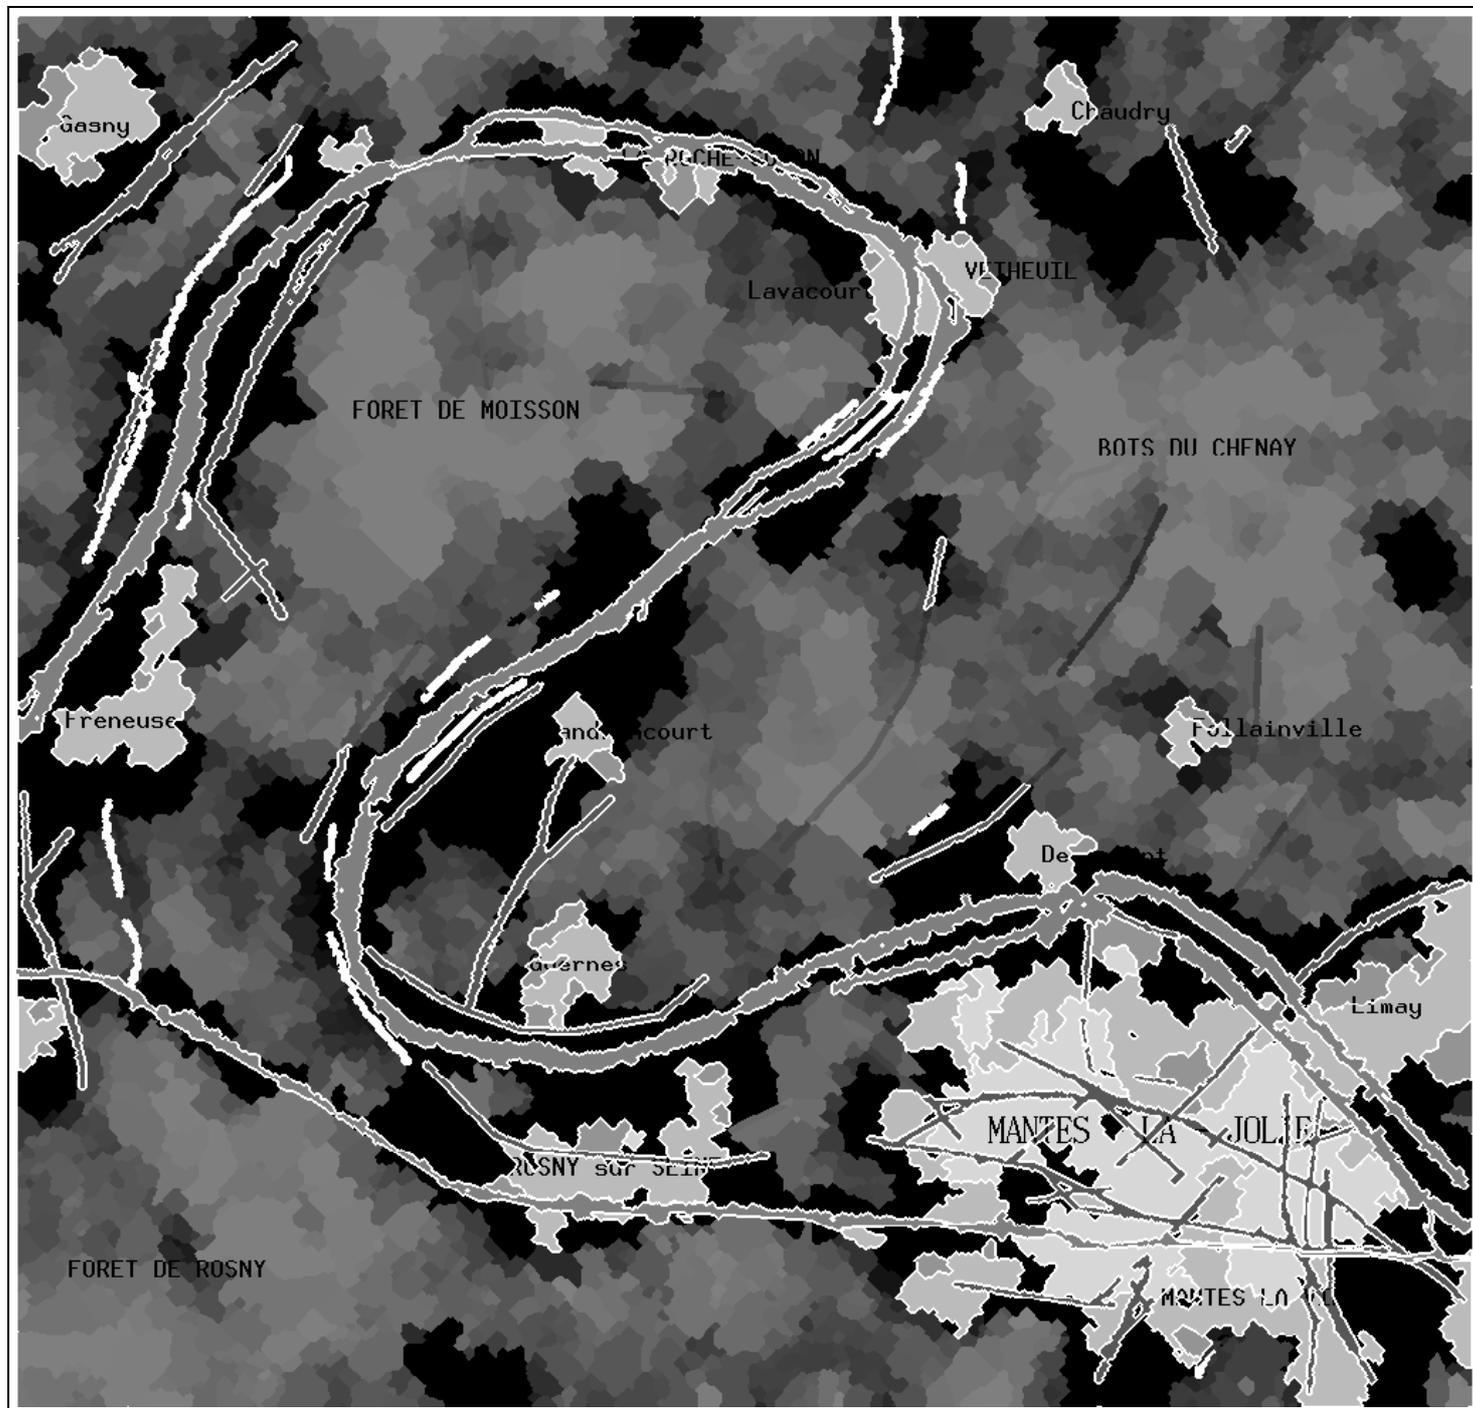


FIG. 8.16 – Résultat de l'interprétation sur Mantes-La-Jolie (annexe A.4)

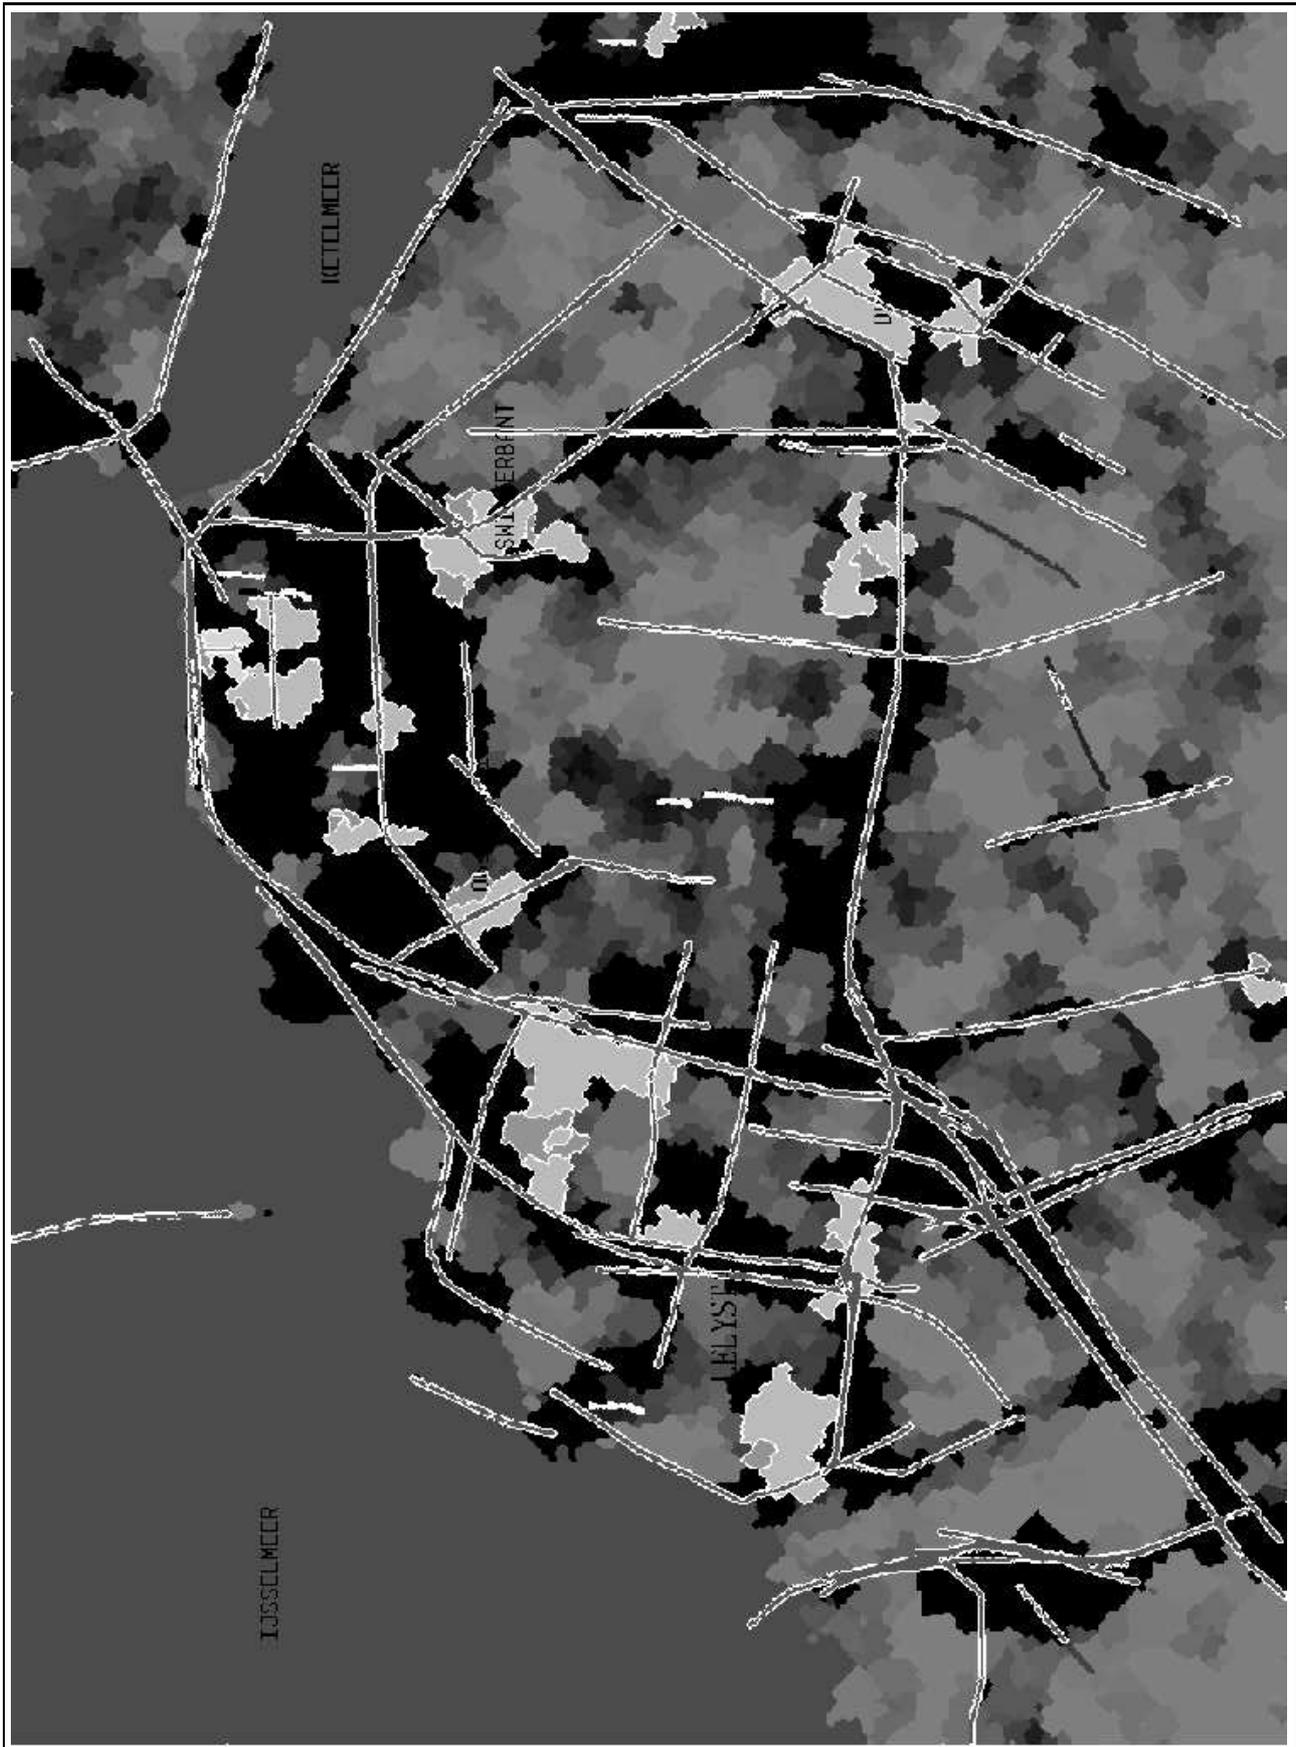


FIG. 8.17 – Résultat de l'interprétation sur les Flevoland (annexe A.2)

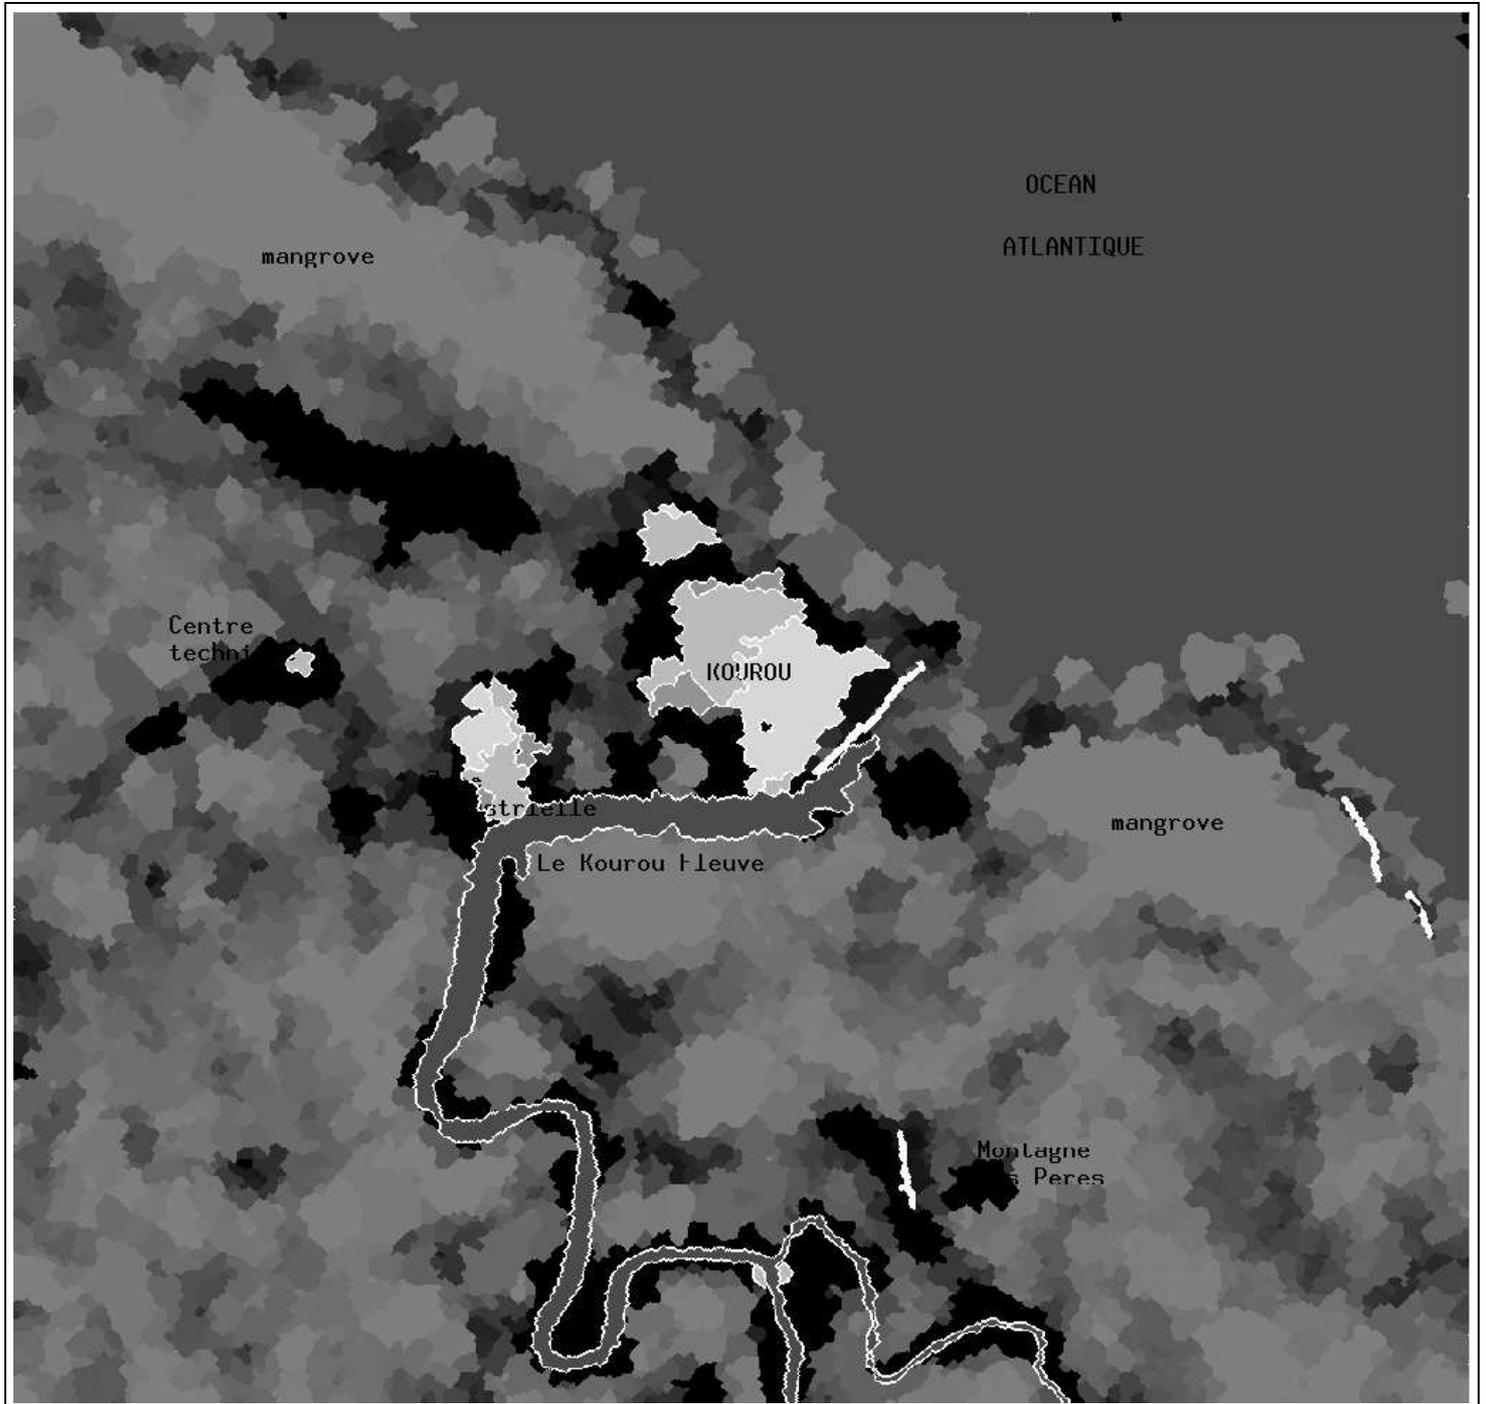


FIG. 8.18 – Résultat de l'interprétation sur Kourou (annexe A.6)



FIG. 8.19 – *Image originale SIR-X/X-SAR (produit MGD)*

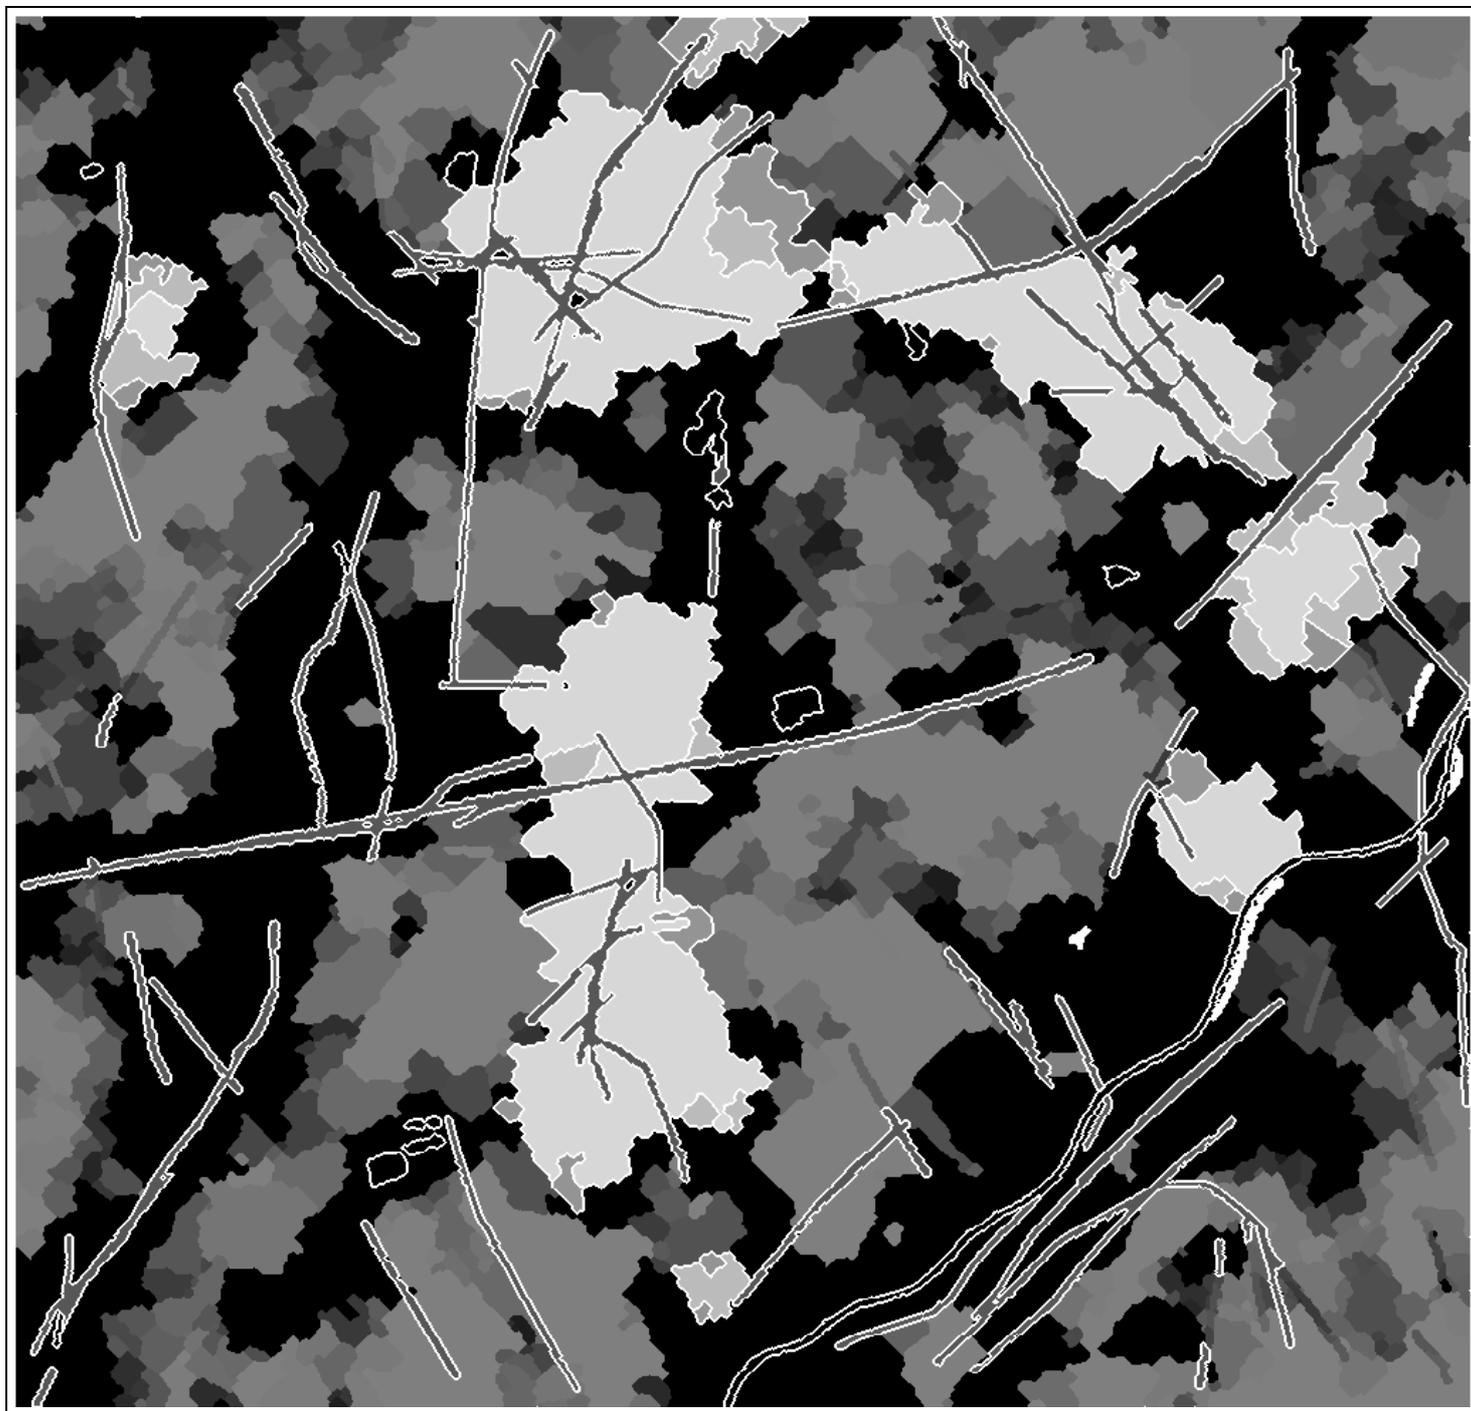


FIG. 8.20 – Résultat de l'interprétation sur une image SIR-X/X-SAR



FIG. 8.21 – *Image originale SIR-X/X-SAR (produit HRMGD)*

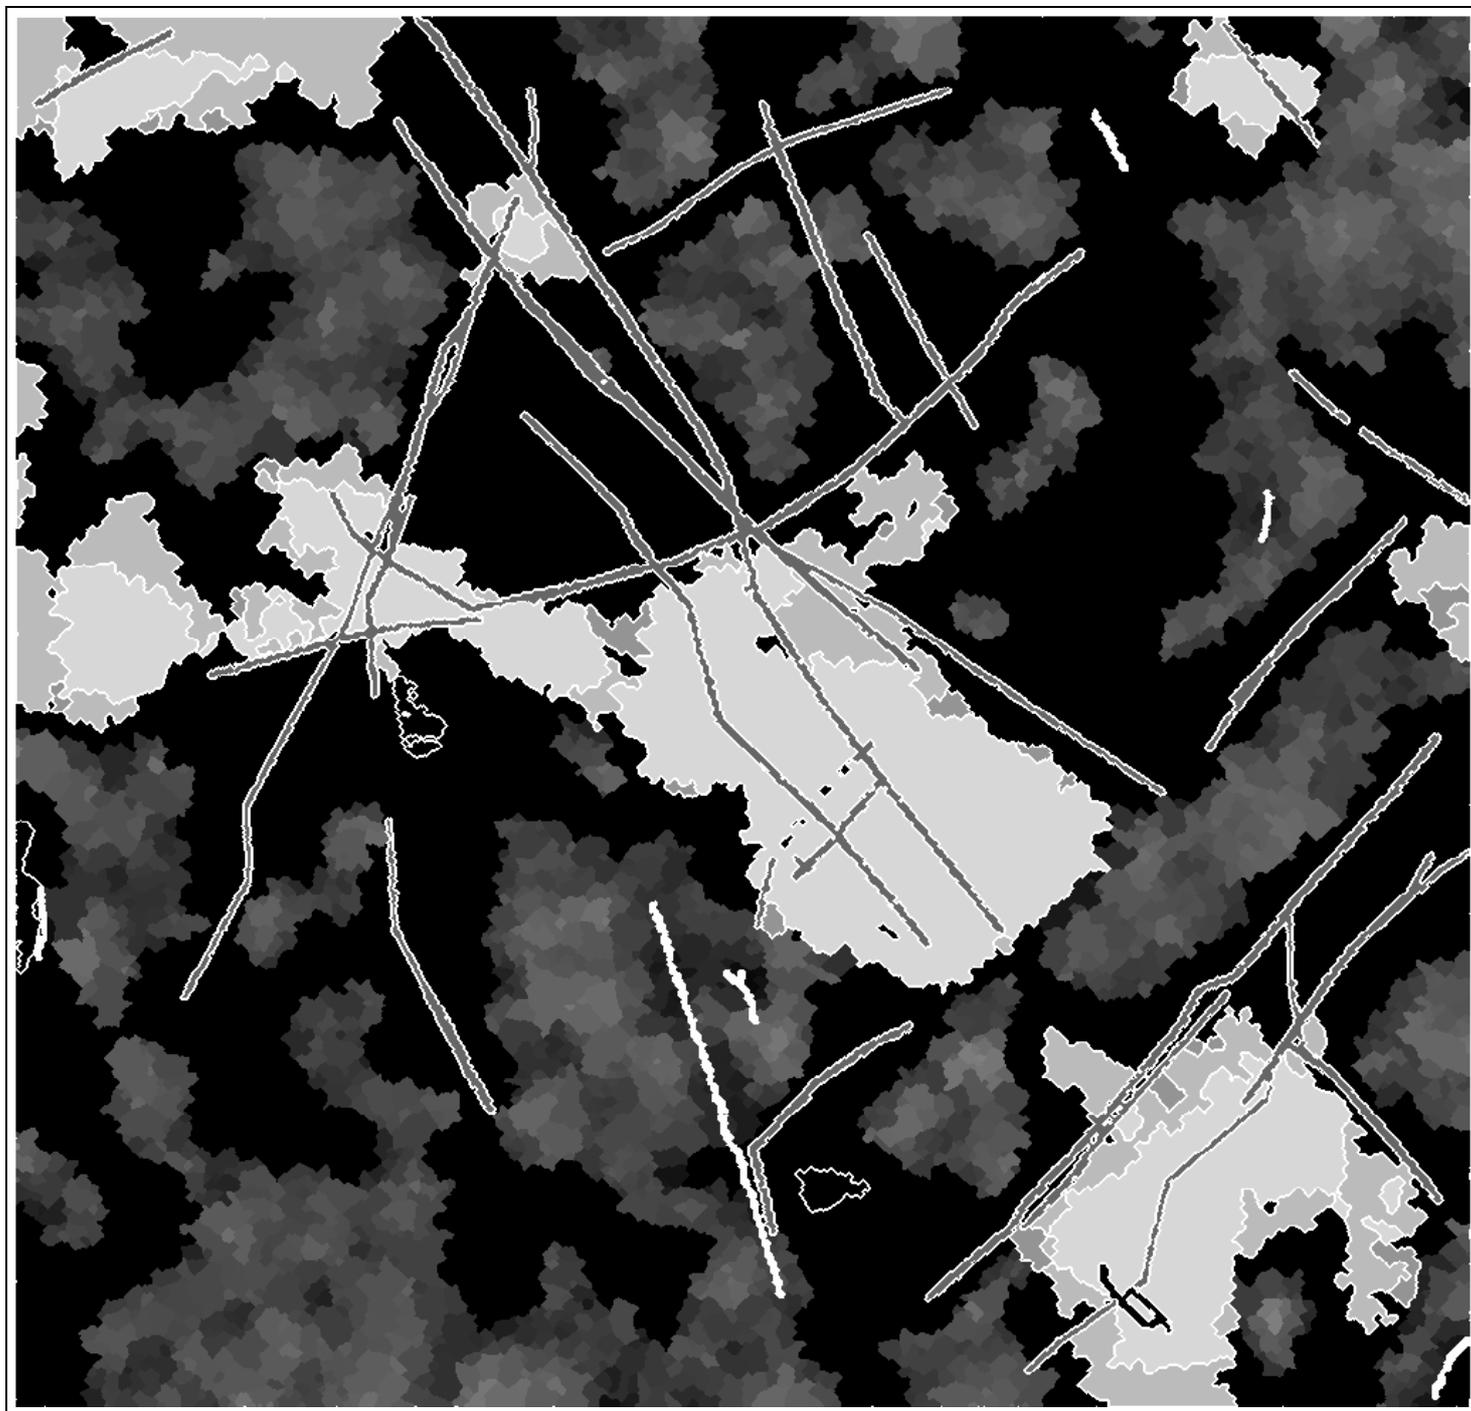


FIG. 8.22 – Résultat de l'interprétation sur une image SIR-X/X-SAR haute résolution 1-vue

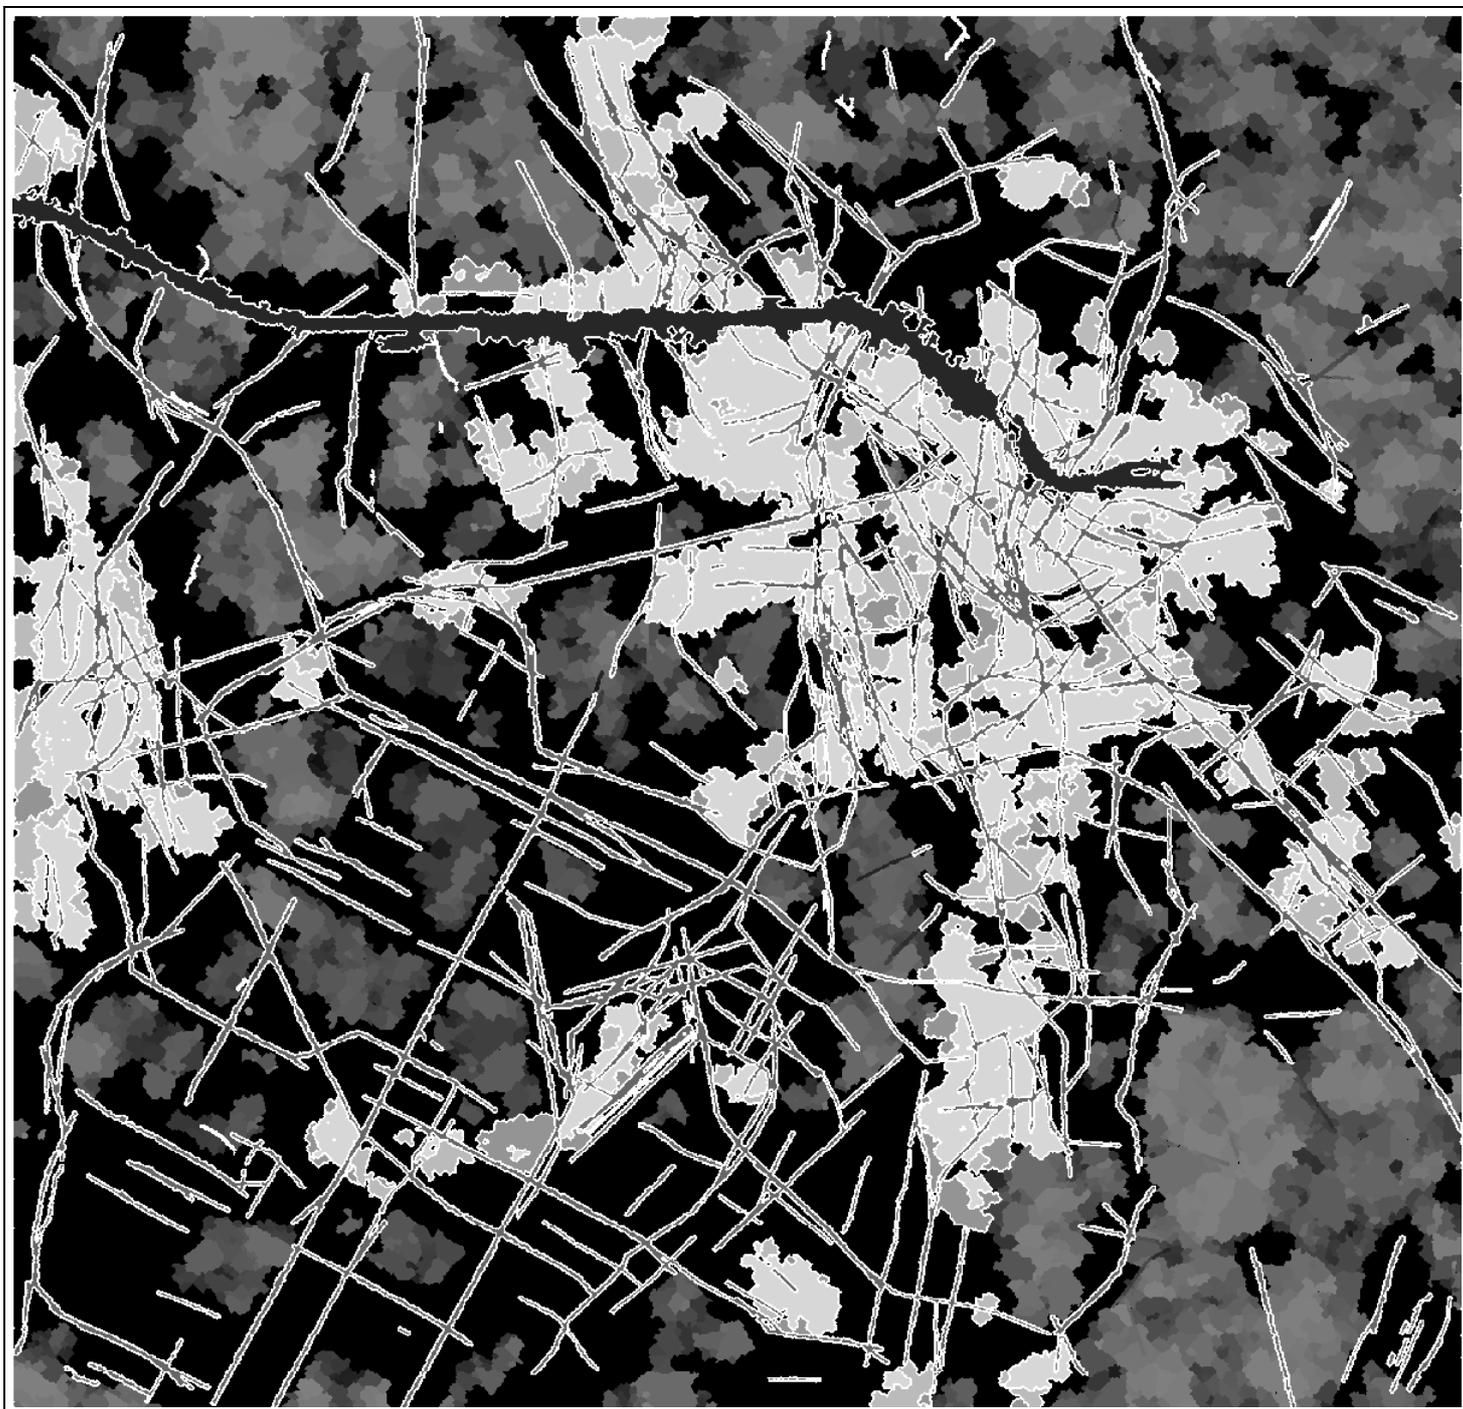


FIG. 8.23 – Résultat de l'interprétation sur l'image RADARSAT 3-vues de la ville d'Amsterdam

## Conclusion

Cette thèse a été consacrée au développement d'une méthode d'analyse et d'interprétation des images de radar à ouverture synthétique obtenue par satellite et donc de résolution moyenne (de l'ordre de la dizaine de mètres). L'objectif était d'exploiter le plus complètement possible les informations disponibles dans une image radar seule, en excluant toute autre source de données complémentaire. Pour répondre à ce cahier des charges, nous avons proposé d'utiliser plusieurs outils élémentaires en parallèle qui ont ensuite été intégrés dans une démarche globale de fusion. Ces outils s'appuient d'une part sur les statistiques spécifiques des images radar, et d'autre part sur des connaissances de plus haut niveau sur les objets recherchés. La modélisation du chatoiement a permis une étude poussée du comportement de certains détecteurs, notamment ceux consacrés aux structures linéaires. Les connaissances de plus haut niveau introduites, qui tiennent compte des propriétés intrinsèques des objets thématiques recherchés, ont souvent été exprimées dans un cadre markovien sur des graphes atypiques (pour la détection des réseaux et du parcellaire dense). Finalement, nous avons proposé un cadre unifié pour fusionner les réponses des différentes détections en utilisant la théorie des croyances et en considérant les outils proposés comme autant de sources d'informations renseignant sur des classes ou des réunions de classes particulières. Cette fusion a permis d'exploiter la complémentarité et la redondance des outils, en particulier pour la discrimination des zones urbaines. Son couplage avec des connaissances contextuelles, qui exploitent les relations spatiales existant entre les objets, permet de lever les dernières ambiguïtés et de procurer un résultat cohérent. Testée sur de nombreuses images de capteurs différents, cette méthode générale a permis d'obtenir des interprétations automatiques satisfaisantes des images, dégageant les entités thématiques principales.

Ainsi, la contribution principale de cette thèse est d'avoir posé un premier jalon pour l'interprétation automatique d'une image radar seule. Une démarche globale allant des outils de bas-niveau jusqu'à l'étape finale d'intégration a été présentée ici et implantée. Nous avons ainsi rempli l'objectif que nous nous étions fixé. Cela étant, et si nous avons dû développer tous les outils nécessaires pour remplir cet objectif, nos contributions les concernant sont plus ou moins importantes. En ce sens, le travail réalisé pour la mise au point d'une technique de détection des réseaux, qui représente la première partie de ce rapport, nous

paraît apporter une solution originale, et il existe, à notre connaissance et à ce jour, peu de résultats comparables. Ainsi, un effort particulier a été effectué dans un premier temps pour étudier les performances du détecteur de lignes proposé (résultat de la fusion de deux détecteurs initiaux) en fonction des paramètres de taille de la fenêtre, contrastes, etc. Ensuite et surtout, la formulation du problème dans un contexte markovien défini sur un graphe de segments pour introduire des contraintes a priori sur les objets recherchés nous paraît être une solution originale et efficace.

La deuxième partie apporte à l'évidence une contribution moindre, bien qu'elle soit nécessaire au schéma global d'interprétation que nous avons développé. Seule, l'étude sur le filtrage des images radar par une méthode de régularisation markovienne avec prise en compte des discontinuités propose une nouvelle solution qui devrait cependant être approfondie (tests d'autres fonctions de régularisation et dans un cadre stochastique). La méthode de segmentation est une méthode markovienne usuelle, même si une contribution à la préservation des lignes par l'introduction d'un champ externe est proposée et une application originale pour la détection du parcellaire est rapportée. Quant au chapitre sur la discrimination des textures, il a surtout pour objet de tester et de comparer des méthodes existantes dans un objectif de discrimination des zones très homogènes ou très hétérogènes.

La troisième et dernière partie de ce rapport, sans être à proprement parler une contribution majeure en tant que telle, a le grand mérite d'unifier notre méthode et de valider, par les résultats qu'elle procure, l'ensemble de la démarche que nous avons adoptée. Caractéristique importante, la démarche globale proposée est très souple et permet facilement l'ajout de nouveaux opérateurs, mais pour un ensemble de classes fixé.

Ainsi, alors que les recherches actuelles s'orientent vers la fusion des images radar avec d'autres sources de données, cette thèse a l'intérêt d'avoir étudié de façon approfondie l'exploitation d'une image radar seule, et posé les premières limites de ce qu'on peut en attendre dans le cadre de la méthode que nous avons employée. Si les résultats obtenus sont globalement corrects, ils sont néanmoins sujets à une très grande variabilité liée à la qualité intrinsèque des images. Les conditions de prise de vue (orientation des réseaux par rapport à la direction de visée, conditions climatiques et de surface pour les régions agricoles) entraînent une variation de la visibilité et des possibilités de discrimination des objets, et ainsi de la qualité de la détection obtenue. Cette thèse constitue donc un premier pas vers l'interprétation automatique ou semi-automatique des images, ou plus prosaïquement constitue un premier instrument d'aide à l'interprétation par des opérateurs humains. La démarche adoptée présente également l'avantage d'être modulaire et les outils "élémentaires" pourront donc être dans l'avenir remplacés ou accompagnés par des outils plus performants.

Les perspectives de prolongement de cette thèse sont nombreuses, tant sur le plan du traitement d'images en général, que sur le plan de l'imagerie radar en particulier.

Sur le plan plus théorique du traitement d'images, nous pensons que les méthodes stochastiques markoviennes, très utilisées au niveau des pixels, apportent également des solutions très efficaces lorsque les graphes sont définis à partir de primitives de plus haut niveau. Le formalisme markovien permet alors d'introduire des connaissances a priori sur la

forme des objets cherchés ou sur la structuration d'une scène, apportant ainsi une solution à des problèmes de haut niveau comme l'interprétation. Ainsi, un prolongement possible à la méthode de détection des réseaux que nous avons proposée pourrait être la détection de bâtiments, pour laquelle des relations simples entre segments pourraient être utilisées. La poursuite de nos recherches dans cette direction soulève néanmoins un problème crucial qui est celui de l'estimation des potentiels des cliques. Le raisonnement qui a pu être mené dans cette thèse à l'aide des boîtes qualitatives d'Azencott ne sera pas possible dans des cas plus complexes, et des solutions doivent être recherchées dans les méthodes d'apprentissage (par exemple à l'aide de réseaux de neurones). Par ailleurs, la démarche proposée, et en particulier l'étape de fusion des réponses de plusieurs détecteurs développés en parallèle, pourraient être appliquées à d'autres problèmes, comme l'interprétation d'images SPOT ou aériennes.

Sur le plan plus spécifique de l'exploitation des images radar, l'introduction de nouvelles connaissances devrait permettre d'améliorer les résultats obtenus qui constituent en quelque sorte une première limite à l'interprétation automatique d'une image seule. Ces nouvelles connaissances peuvent être introduites sous des formes très variées.

La première source d'informations est celle constituée par d'autres images radar prises à des dates différentes. Le multi-temporel nous semble à l'heure actuelle une des voies les plus prometteuses pour l'exploitation des images radar. L'accumulation des prises de vues depuis la mise en service des différents satellites civils permet la construction d'images avec un très grand nombre équivalent de vues, et donc une lisibilité accrue. L'adaptation de la méthode proposée et des outils développés dans cette thèse peut être envisagée de plusieurs façons. Une première solution peut consister à filtrer l'image et interpréter l'image améliorée ainsi obtenue. Plusieurs interrogations sont soulevées par cette approche et donc plusieurs points devraient être étudiés. Tout d'abord, on peut se demander quels filtres multi-temporels doivent être utilisés. La réponse dépendra à n'en pas douter des objets thématiques envisagés : si pour les réseaux routiers et hydrographiques ou le milieu urbain, relativement stables d'une vue à l'autre, un simple moyennage apportera rapidement des résultats convaincants, la détection des limites du parcellaire, variables d'une vue à l'autre, exigera une autre solution. Ensuite, se posera la question de l'adaptation des outils "élémentaires" aux images filtrées. On peut supposer qu'à partir d'un certain nombre de vues, qui demandera à être déterminé, les outils que nous avons utilisés auront avantage à être remplacés, par exemple, par des détecteurs adaptés aux images optiques. Il sera dans tous les cas indispensable de pouvoir paramétrer la méthode par le nombre de vues de l'image filtrée. Une seconde solution, diamétralement opposée, consisterait à fusionner non pas les images radar originales pour obtenir une image "radar" améliorée, mais à fusionner les différentes interprétations effectuées sur chaque image radar pour obtenir une interprétation de meilleure qualité. Plus simple à mettre en œuvre avec les outils dont nous disposons et capable de gérer plus facilement des nombres de vue différents, cette démarche augmente néanmoins considérablement le temps de calcul.

Si l'utilisation du multi-temporel est la perspective la plus naturelle, l'introduction d'autres sources d'informations, comme des images issues de capteurs différents ou des informations symboliques apportées par une carte, serait également une voie intéressante à poursuivre. La fusion SPOT-SAR pose de nombreux problèmes liés notamment aux différences de prise de

vue des images, et surtout aux déformations induites par l'échantillonnage en distance de l'imagerie radar. Le passage par une source d'informations symboliques nous paraît plus prometteur. Une connaissance grossière de la zone imagée, accessible par une carte ou un système d'information géographique, permettrait de confronter les deux interprétations qui peuvent être extraites de l'image radar et de la carte. Elle permettrait de mettre en correspondance les détections des objets thématiques, d'en valider certaines et d'en infirmer d'autres. Cette démarche nous paraît la plus prometteuse, car elle s'inspire du comportement humain. En effet, l'opérateur humain n'est pas lui-même d'une très grande fiabilité dans son interprétation de l'image radar en l'absence de carte. De plus, le problème n'est pas trivial car même grossièrement recalées (même orientation, recouvrement approximatif de la même zone) les déformations dues au relief restent très importantes et ne permettent que de considérer des zones d'influence où se trouvent potentiellement les objets recherchés.



# **Annexes**



# Annexe A

## Base de données

*Nous décrivons dans cette annexe les principales régions sur lesquelles les techniques proposées ont été testées. Pour tenir compte de la grande diversité d'aspects des images, plusieurs zones présentant des caractéristiques très différentes ont été sélectionnées. Ainsi, la variation du niveau de difficulté des régions permet d'illustrer les performances et les limites de la méthode et des outils proposés. Nous avons choisi de présenter les images accompagnées d'une carte mettant en évidence les objets cartographiques (réseaux routiers et fluviaux, milieux urbain et industriel, mer, forêt, relief) qui nous intéressent. Nous commençons par décrire chaque scène ainsi que les régions qui ont été sélectionnées dans celle-ci, puis un tableau récapitulatif résume la présence des objets sémantiques et la difficulté de détection.*

### A.1 Introduction

Cette thèse est consacrée à l'interprétation automatique des images radar satellitaires. Aussi, nous sommes nous limités à ces seules données, avec une priorité accordée aux images du capteur ERS-1. Cependant, nous avons parfois disposé d'images prises par les radars des satellites JERS-1, RADARSAT ou de la navette SIR-C/X-SAR. Le tableau ci-dessous résume les caractéristiques des capteurs embarqués.

TAB. A.1 – *Quelques caractéristiques des radars embarqués*

Capteurs	Angle d'incidence	Bande	Produit	Nombre de vues	Résolution	Espacement inter-pixels
ERS-1	23°	C	PRI	3	25 m	12,5 m
JERS-1	38°	L		3	25 m	12,5 m
ALMAZ	30°	S			15 m?	7,5 m?
SIR-C/X-SAR	38°	X	MGD	3	25 m	12,5 m
			HRMGD	1	10 m	6,25 m
RADARSAT	20°	C	Standard	4	25 m	12,5 m
	37°	C	Fine	1	9 m	

Nous tenons ici à remercier J.P. Rudant pour les nombreuses images qu'il nous a procurées.

Nous présentons dans les paragraphes suivants les régions sur lesquelles nous avons travaillé. Pour aider le lecteur, une carte (parfois recalée) accompagne chaque image (suivant les cas, cartes IGN ou Michelin au 1 :25 000, 1 :100 000 ou 1 :400 000). Les interprétations automatiques (résultats du chapitre 8) seront à comparer autant avec les images radar originales qu'avec les cartes, car de nombreux objets présents sur ces dernières, notamment un grand nombre de routes, sont difficilement discernables à l'œil nu sur l'image radar et ne sont donc pas détectés automatiquement.

## A.2 Scène des Pays-Bas

C'est une des premières images délivrées par le radar d'ERS-1 et elle est de très bonne qualité. En effet, cette région est particulièrement plate et l'image ne présente pratiquement aucune déformation géométrique due au relief. De plus, plusieurs parties de cette région sont des polders irrigués par de nombreux canaux et soumis à une culture intensive. Le parcellaire est ainsi très marqué (à la date où a été prise cette image) et découpé géométriquement le long des canaux ou des routes qui sont également très visibles<sup>1</sup>. En revanche, l'urbain présente un aspect assez peu contrasté comparé à d'autres données. Cela s'explique par l'habitat de ces polders, constitué par des maisons basses -deux étages en général- souvent agrémentées d'un jardin et délimitées par des rues bordées d'arbres [Duin].

Cette image est facilement interprétable à l'œil, les réseaux routiers et hydrographiques étant très marqués, tout comme le parcellaire qu'ils structurent. Elle nous servira de zone test pour vérifier la pertinence des outils dans un cas particulièrement simple.

Nous avons sélectionné deux régions sur cette scène qui couvre une grande partie du IJsselmeer des Pays-Bas. Il s'agit de deux zones de polders, l'une recouvrant le Flevoland et centrée sur la ville de Lelystad (fig.A.1 et A.2), et l'autre contenant le Wieringermeer (fig.A.4 et A.5)-cf. tab.A.2.

TAB. A.2 – Zone des Pays-Bas

<b>Flevoland : 1500 × 1100</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	forte	forte	faible	forte	moy.	forte	
Difficulté	faible	faible	forte	faible		faible	
<b>Wieringermeer : 800 × 1100</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	forte	forte		faible		forte	
Difficulté	faible	faible		faible		faible	

Nous disposons également sur cette région d'une image JERS-1, mais elle est de mauvaise qualité, sauf en ce qui concerne l'urbain qui apparaît très clairement. Cette région a aussi été imagée par le capteur radar du satellite RADARSAT, et est disponible sur le CD public "RADARSAT Sample Images". Nous l'utiliserons parfois pour tester la généralité de nos outils sur les images radar satellitales. Notons que si les réseaux apparaissent également très bien sur cette image, le parcellaire est moins contrasté et apparaît plutôt comme un fond uniforme. En revanche, les milieux urbain et industriel présentent de très fortes radiométries (les confusions avec les champs sont moindres) qui rend leur détection plus aisée. Ceci est dû à un codage différent du signal pour les images RADARSAT<sup>2</sup>.

1. Cette image est très souvent utilisée pour illustrer les techniques de filtrage car les forts contrastes entre les différents champs mettent bien en évidence le lissage.

2. D'une façon générale toute la dynamique est toujours utilisée dans le cas des images RADARSAT (la valeur maximale est à 65 635), alors que sur les images ERS-1, le maximum radiométrique est souvent très inférieur à la valeur maximale.



FIG. A.1 – *Image des Flevoland* ©ESA.

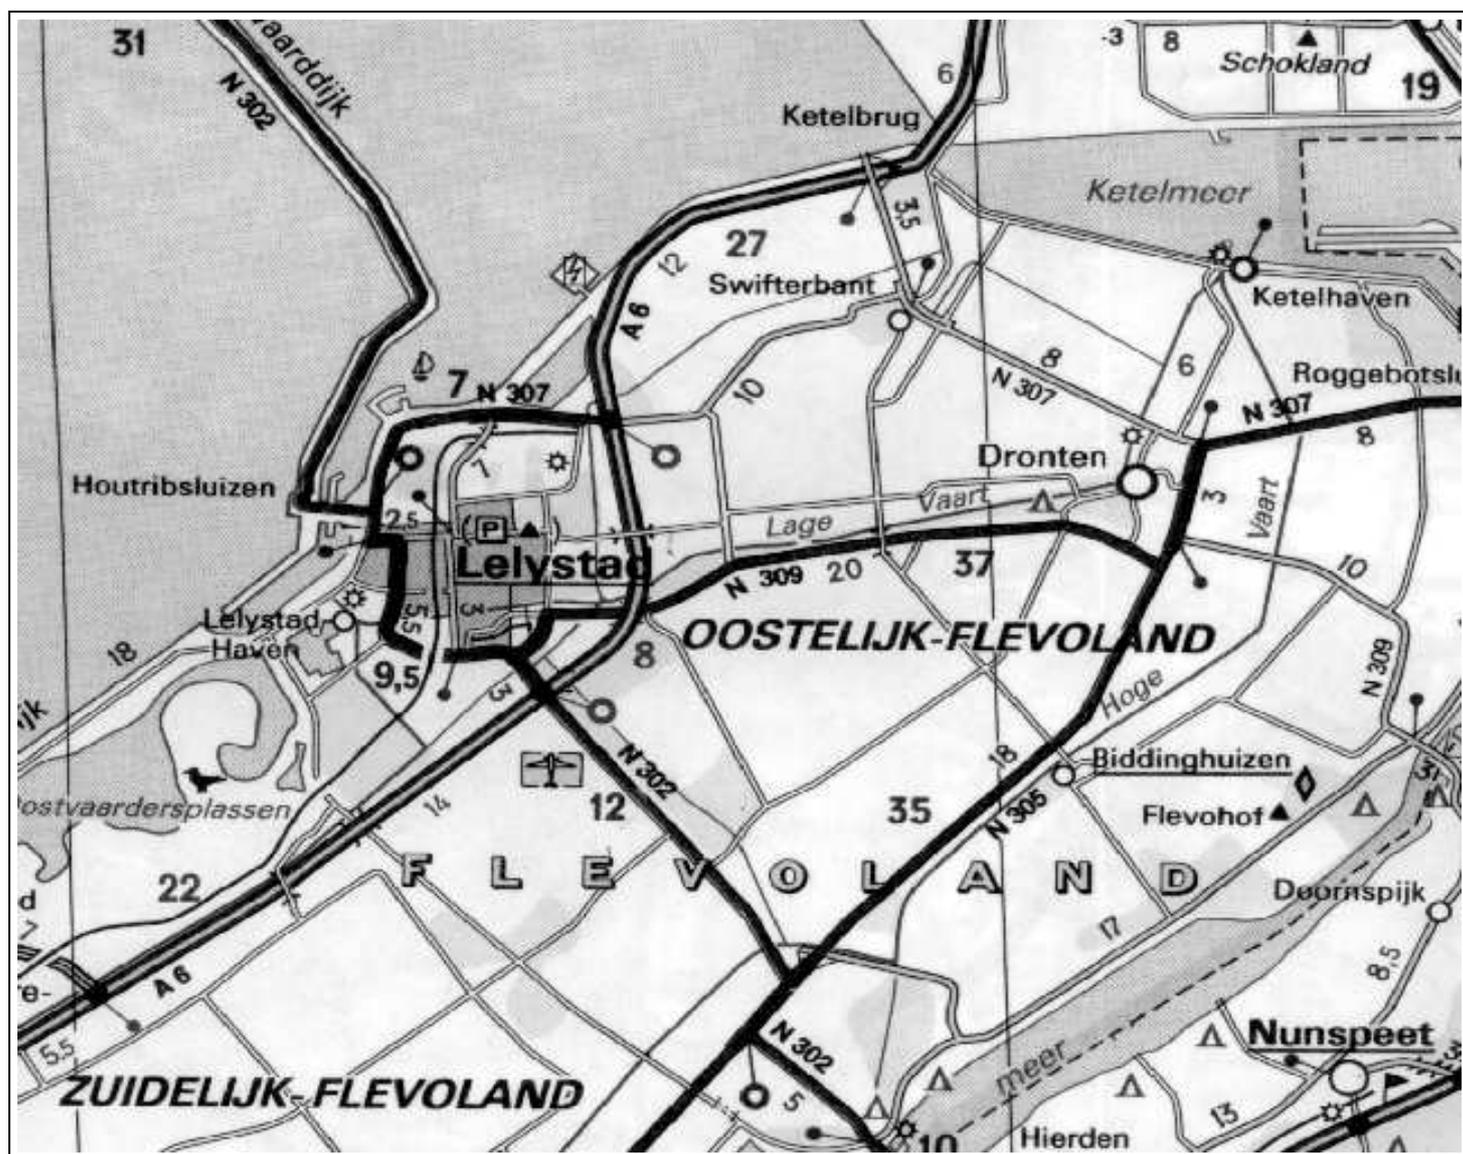


FIG. A.2 – Carte correspondant à l'image des Flevoland.



FIG. A.3 – Image RADARSAT des Flevoland ©Agence Spatiale Canadienne.



FIG. A.4 – Image du Wieringermeer ©ESA.



FIG. A.5 – Carte ©Michelin correspondant à l'image du Wieringermeer.

## A.3 Scène de Bretagne

Cette image recouvre une grande partie de la pointe de la Bretagne, légèrement à l'Est de Brest, entre Saint Briec et Lorient du Nord au Sud. Cette région présente une difficulté intermédiaire, à mi-chemin entre la scène des Pays-Bas et celle d'Aix-en-Provence. Elle est en effet vallonnée, sans toutefois présenter de déformations trop importantes dues au relief.

Des zones agricoles et forestières la constituent, mais il ne s'agit pas (sur une image mono-date) d'un parcellaire marqué, et il apparaît plutôt comme un fond uniforme. Seuls quelques champs sombres et d'autres très brillants<sup>3</sup> dénotent le parcellaire.

En ce qui concerne l'urbain, les villes présentes sur ces images sont de taille modeste et se caractérisent par leur texture constituée d'une alternance de points très brillants et sombres, généralement avec une forte dynamique. Cependant, des confusions sont parfois possibles avec les champs clairs.

Le réseau routier est, quant à lui, relativement visible, même si cette visibilité est très dépendante de l'orientation de la route par rapport à la direction incidente du radar. Ainsi, certains grands axes routiers sont difficilement visibles à l'œil, alors que des réseaux de moindre importance, mais orientés de façon favorable (perpendiculairement à la direction incidente), apparaissent clairement [Hend-88]. De plus, des cours d'eau dans des vallées encaissées structurent également le paysage.

Nous avons sélectionné sur cette scène une région comprise entre Lorient et Hennebont. Cette image est dans l'ensemble de difficulté moyenne (cf. tabA.3 et fig.A.6 et A.7).

TAB. A.3 – Zone de Bretagne

<b>Lorient</b> : 1024 × 1024							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	forte	moy.	moy.	faible		moy.	
Difficulté	moy.	forte	moy.	moy.		forte	

Nous disposons en réalité de quatre bandes de la même zone (deux orbites montantes et deux orbites descendantes). Les images ont été sélectionnées sur la bande qui nous a semblé de la meilleure qualité.

3. Ils sont probablement dus à des champs labourés et très humides lors de la prise de vue.

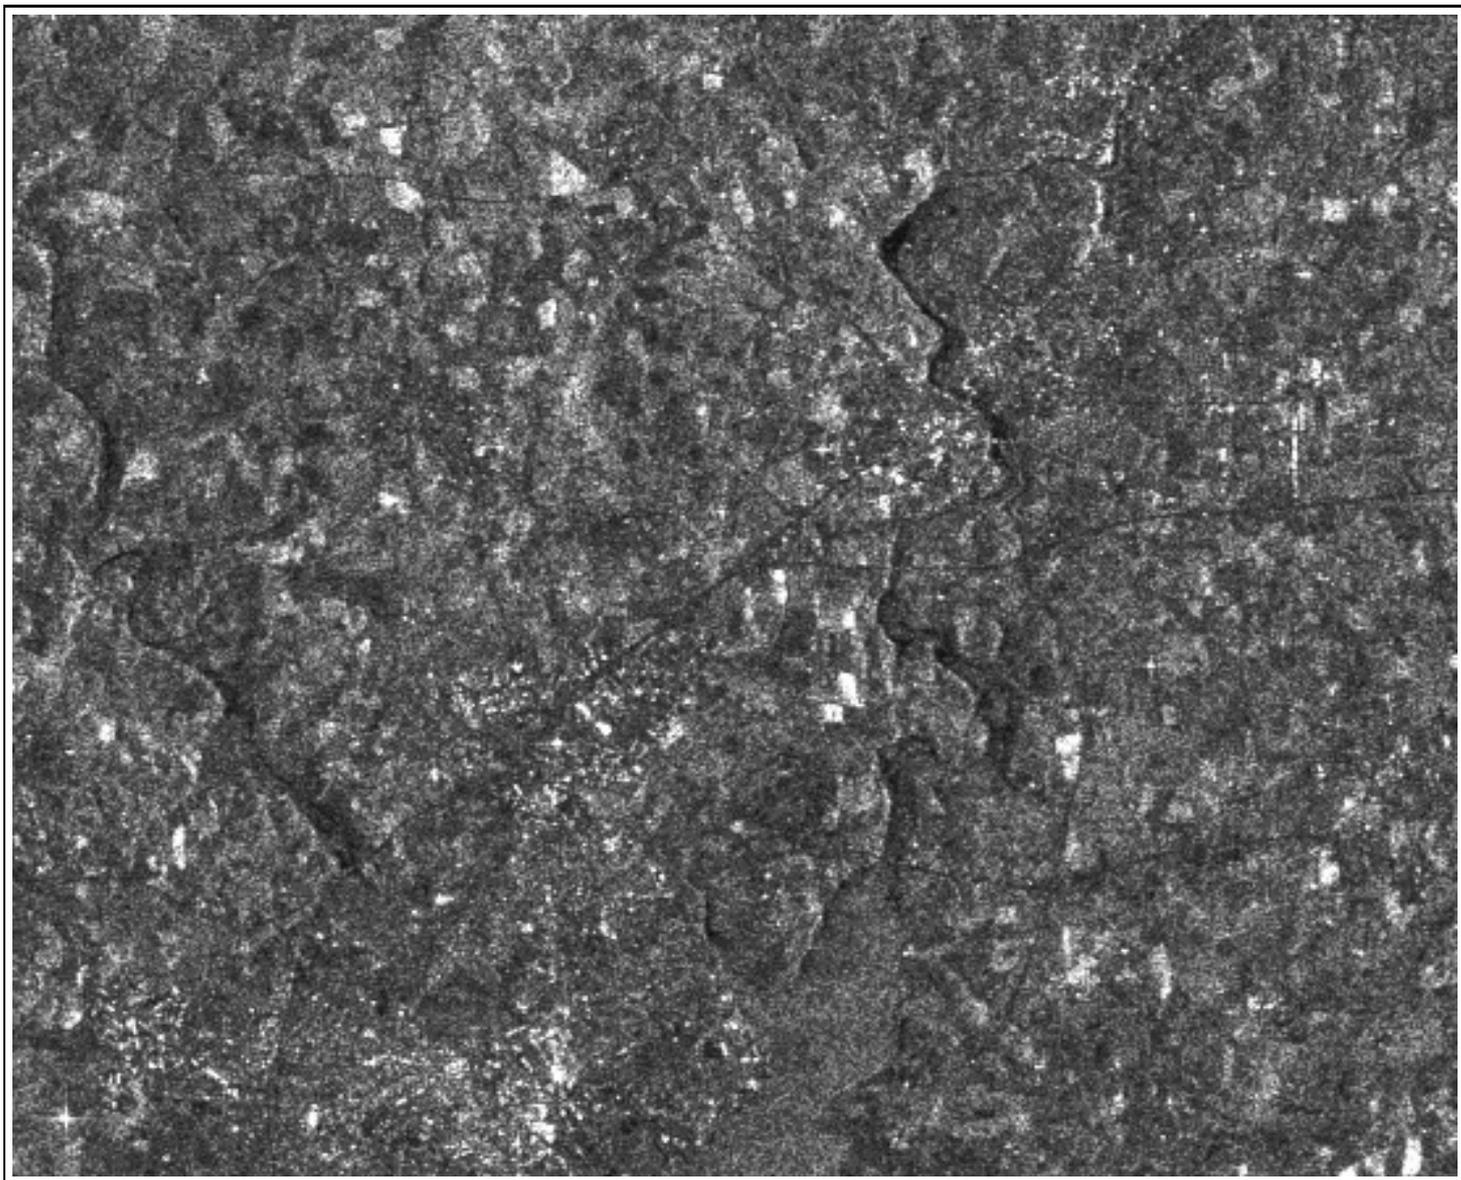


FIG. A.6 – *Image originale de Lorient* ©ESA.

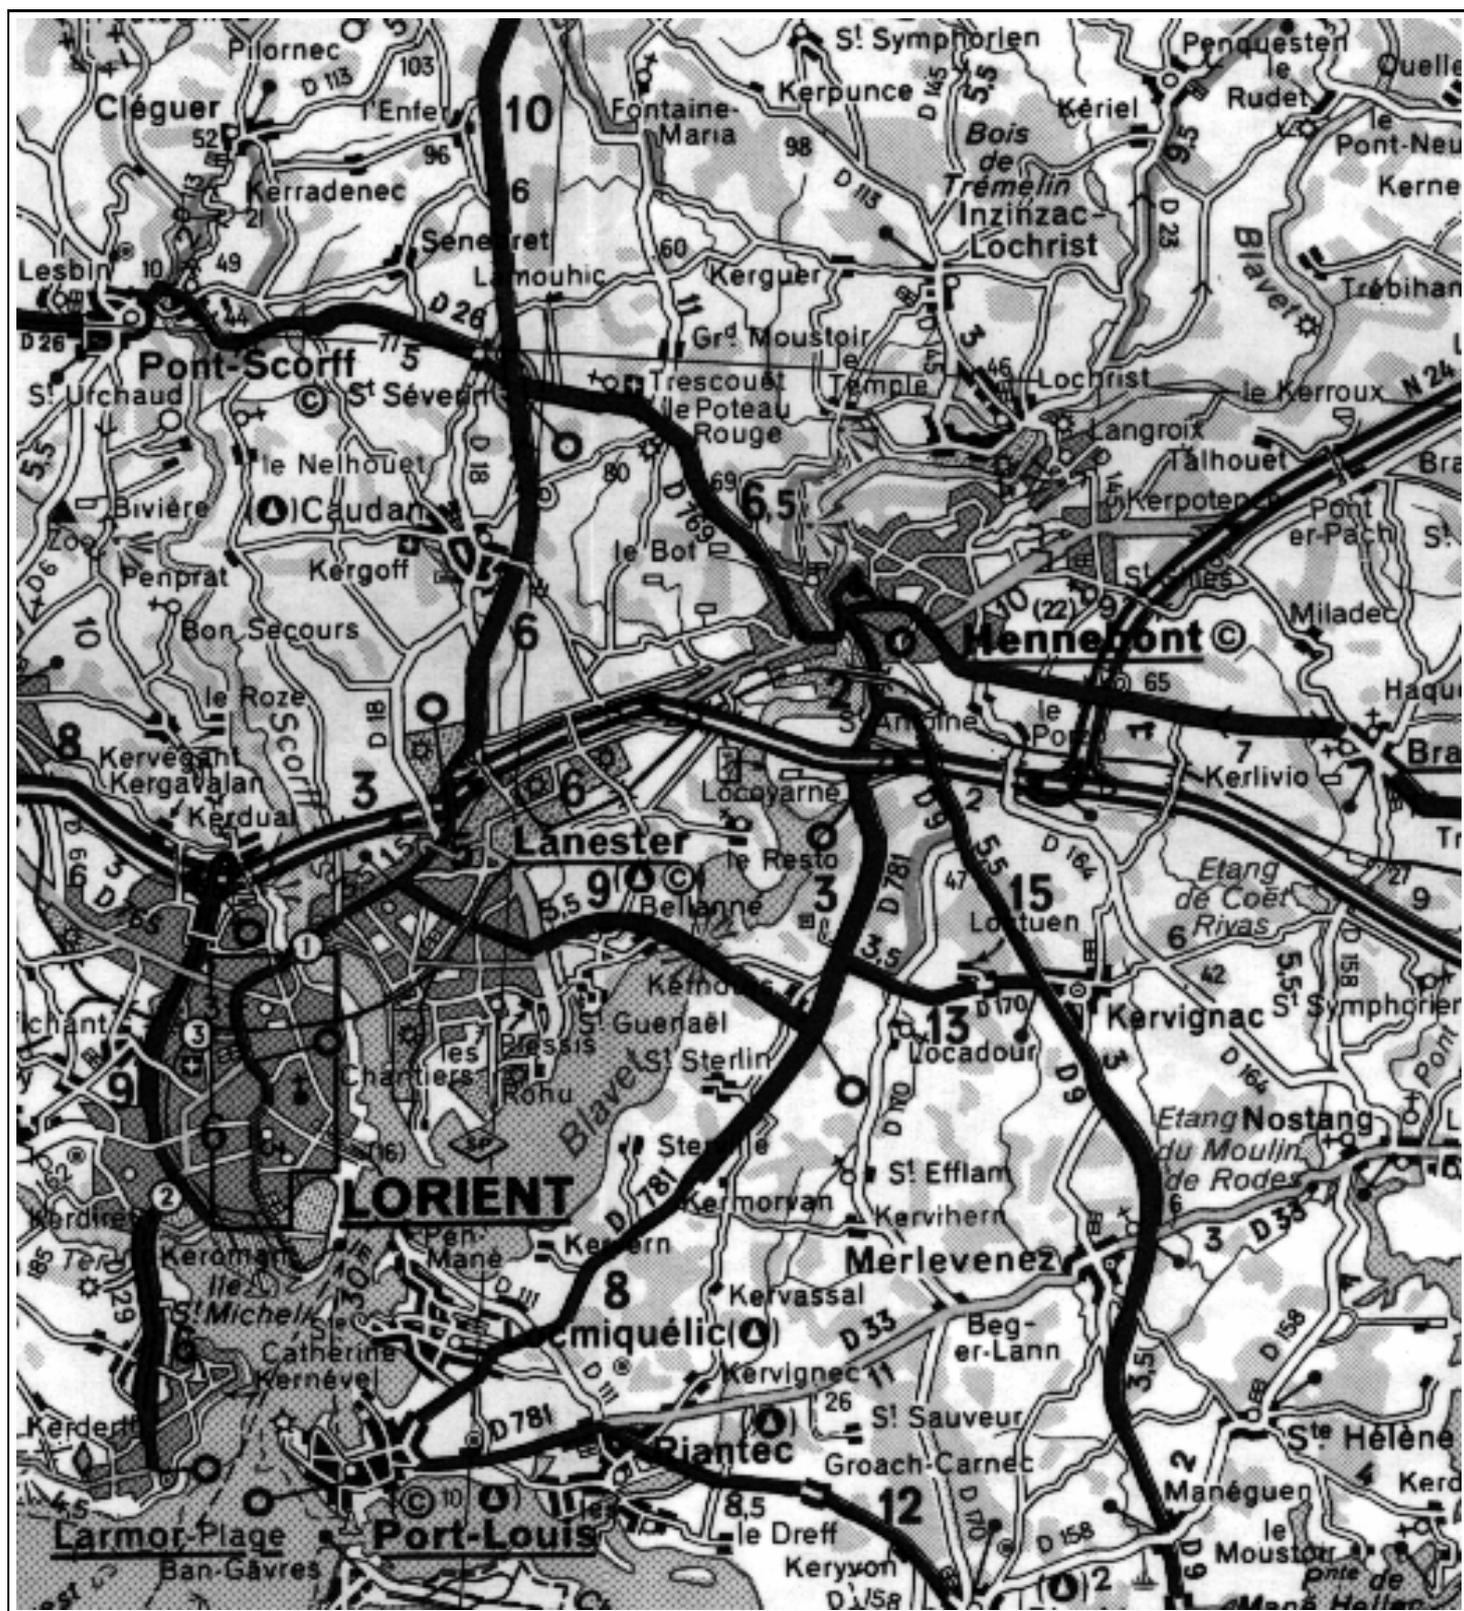


FIG. A.7 – Carte ©Michelin correspondant à l'image de Lorient.

## A.4 Scène de Paris

Cette scène va de Vernon à Marne La Vallée, d'Ouest en Est, et Paris et son agglomération en occupe une grande partie. Nous avons utilisé cette scène pour tester le comportement de certains algorithmes en urbain très dense. Le relief est faible et l'image présente peu de déformations géométriques. Le réseau routier est généralement assez visible, mais l'omniprésence des réflexions spéculaires sur Paris modifie complètement les conditions de détection. Le réseau hydrographique, et en particulier la Seine, est bien visible.

Les régions sélectionnées, au nombre de trois, répondent à des problématiques diverses. Une première zone centrée sur Paris permet de se placer dans des conditions d'urbain extrêmement dense. Une deuxième zone, centrée sur l'aéroport de Roissy-Charles de Gaulle, présente un réseau routier bien marqué en terrain plat (fig.A.8 et fig.A.9). La troisième image est une zone test pour la détection du réseau hydrographique (fig.A.10 et fig.A.11). Elle représente une des circonvolutions de la Seine aux environs de Mantes-la-Jolie et la Roche-Guyon (cf. tab.A.4).

TAB. A.4 – Zone de Paris

<b>Paris : 1024 × 1024</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	forte	moy.	très forte				
Difficulté	forte	moy.	faible				
<b>Roissy : 1024 × 1024</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	moy.	néant	forte				
Difficulté	faible		moy.				
<b>Seine : 1024 × 1024</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	faible	forte	moy.	néant	faible		
Difficulté	moy.	forte	moy.		forte		

Sur la région parisienne, nous disposons également d'une image du satellite ALMAZ. L'angle d'incidence plus grand et la résolution plus fine procurent une vision totalement différente du réseau routier et du milieu urbain. Des tests seront aussi réalisés sur deux images : l'une centrée sur Paris, et l'autre sur Versailles.

## A.5 Scène d'Aix-en-Provence

Cette zone couvre une région entre Apt et Marseille du Nord au Sud. Le relief y est suffisamment marqué pour que de nombreuses déformations géométriques limitent la lisibilité de l'image dans les zones accidentées. Elle présente de grands centres urbains très denses comme Marseille ou Aix-en-Provence. Par ailleurs, le réseau routier est peu visible à l'exception des très grands axes souvent autoroutiers. En revanche, il y a plusieurs grandes zones de forêt et des zones agricoles.

Nous avons sélectionné une zone centrée sur la ville d'Aix-en-Provence (fig.A.12 et A.13). Elle présente l'intérêt de montrer plusieurs types d'urbain, allant de l'urbain très dense aux zones industrielles. Les axes routiers sont difficilement visibles, bien que la carte atteste un réseau très dense lui aussi (cf. tab.A.5).

TAB. A.5 – Zone d'Aix-en-Provence

<b>Aix-en-Provence : 1024 × 1024</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	moy.		très forte		forte	faible	forte
Difficulté	forte		moy.		moy.	forte	moy.

D'autre part, certains des outils ont été testés sur la scène entière pour étudier leurs comportements sur une image de grande taille.

## A.6 Scène de Guyane

La scène recouvre une partie de la Guyane Française centrée sur la ville de Kourou. A l'exception de quelques centres urbains, cette image est surtout constituée par des mangroves, des forêts et des savanes. Le faible réseau routier est difficilement visible, mais en revanche, le réseau hydrographique, notamment le fleuve Kourou, est nettement marqué.

Une région centrée sur Kourou et comprenant une partie d'Océan Atlantique a été choisie (fig:A.14 et A.15). Il s'agira sur cette zone facile à interpréter de tester la validité des outils, notamment pour la détection des zones homogènes et du milieu urbain (cf. tab.A.6).

TAB. A.6 – Zone de Guyane

<b>Kourou : 1024 × 1024</b>							
	<i>Rés. routier</i>	<i>Rés. hydro.</i>	<i>Urbain</i>	<i>Mer</i>	<i>Forêt</i>	<i>Parcell.</i>	<i>Relief</i>
Présence	faible	forte	moy.	forte	forte		faible
Difficulté	forte	faible	moy.	faible	moy.		moy.

Une image JERS-1 de la même région est également disponible, ainsi que plusieurs images RADARSAT.



FIG. A.8 – *Image originale de Roissy* ©ESA.

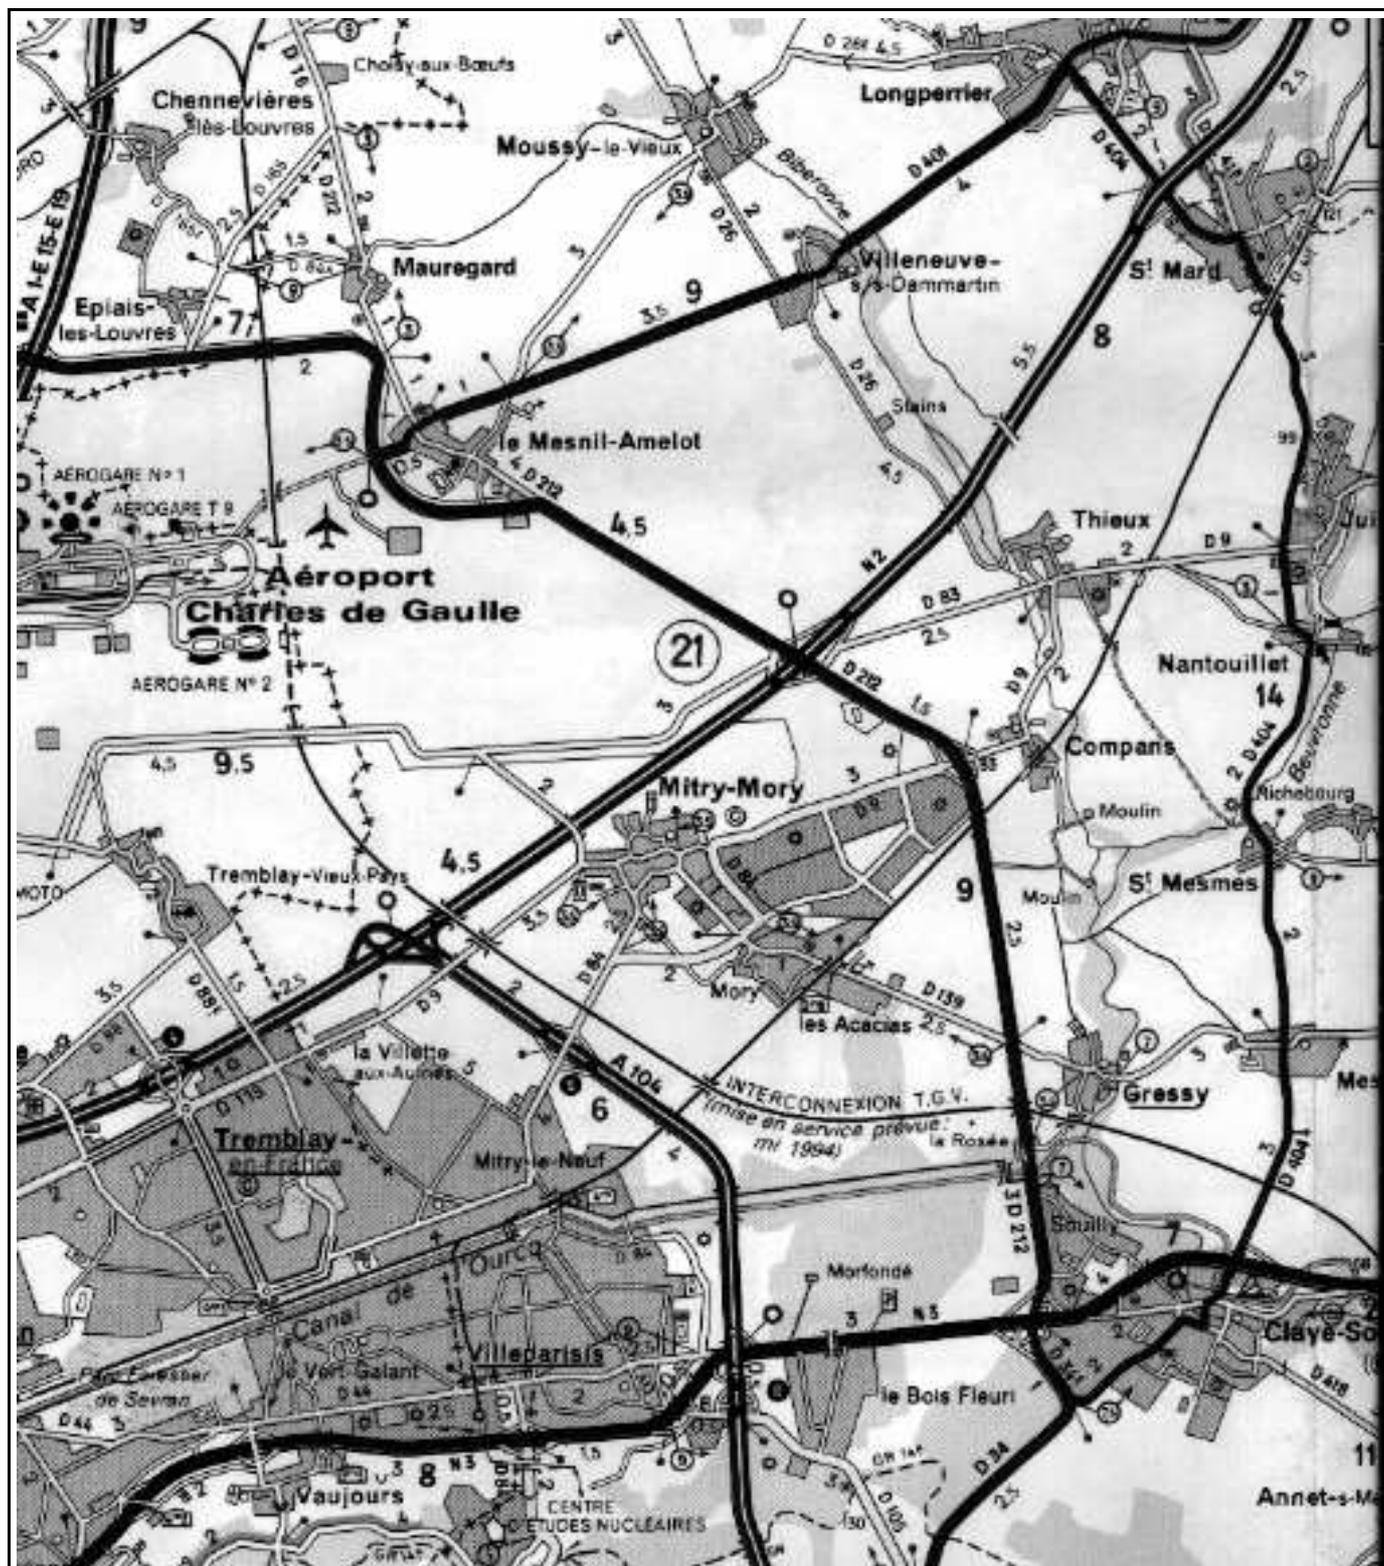


FIG. A.9 – Carte ©Michelin correspondant à limage de Roissy.



FIG. A.10 – *Image originale de la Seine (près de Mantes-la-Jolie) ©ESA.*

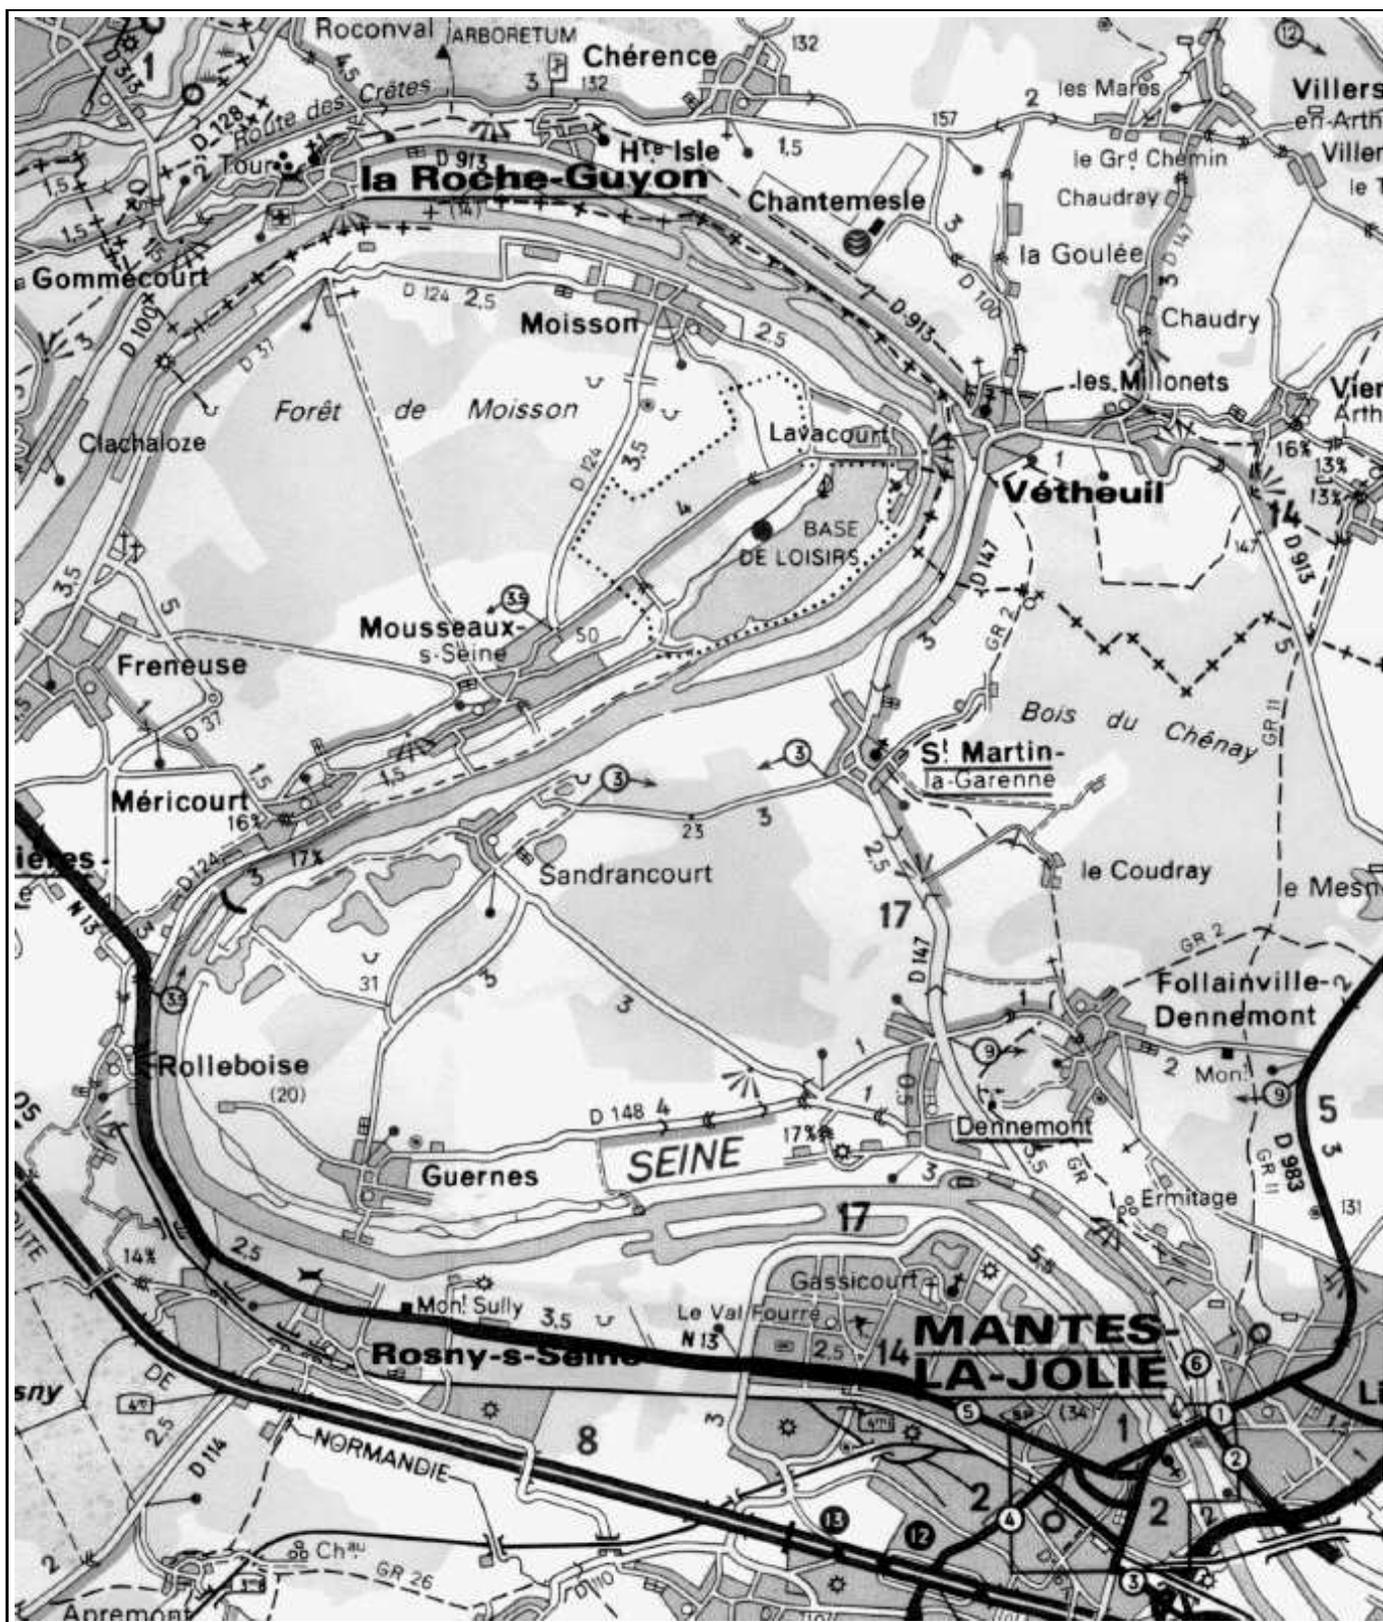


FIG. A.11 – Carte correspondant à l'image de Mantes-La-Jolie.

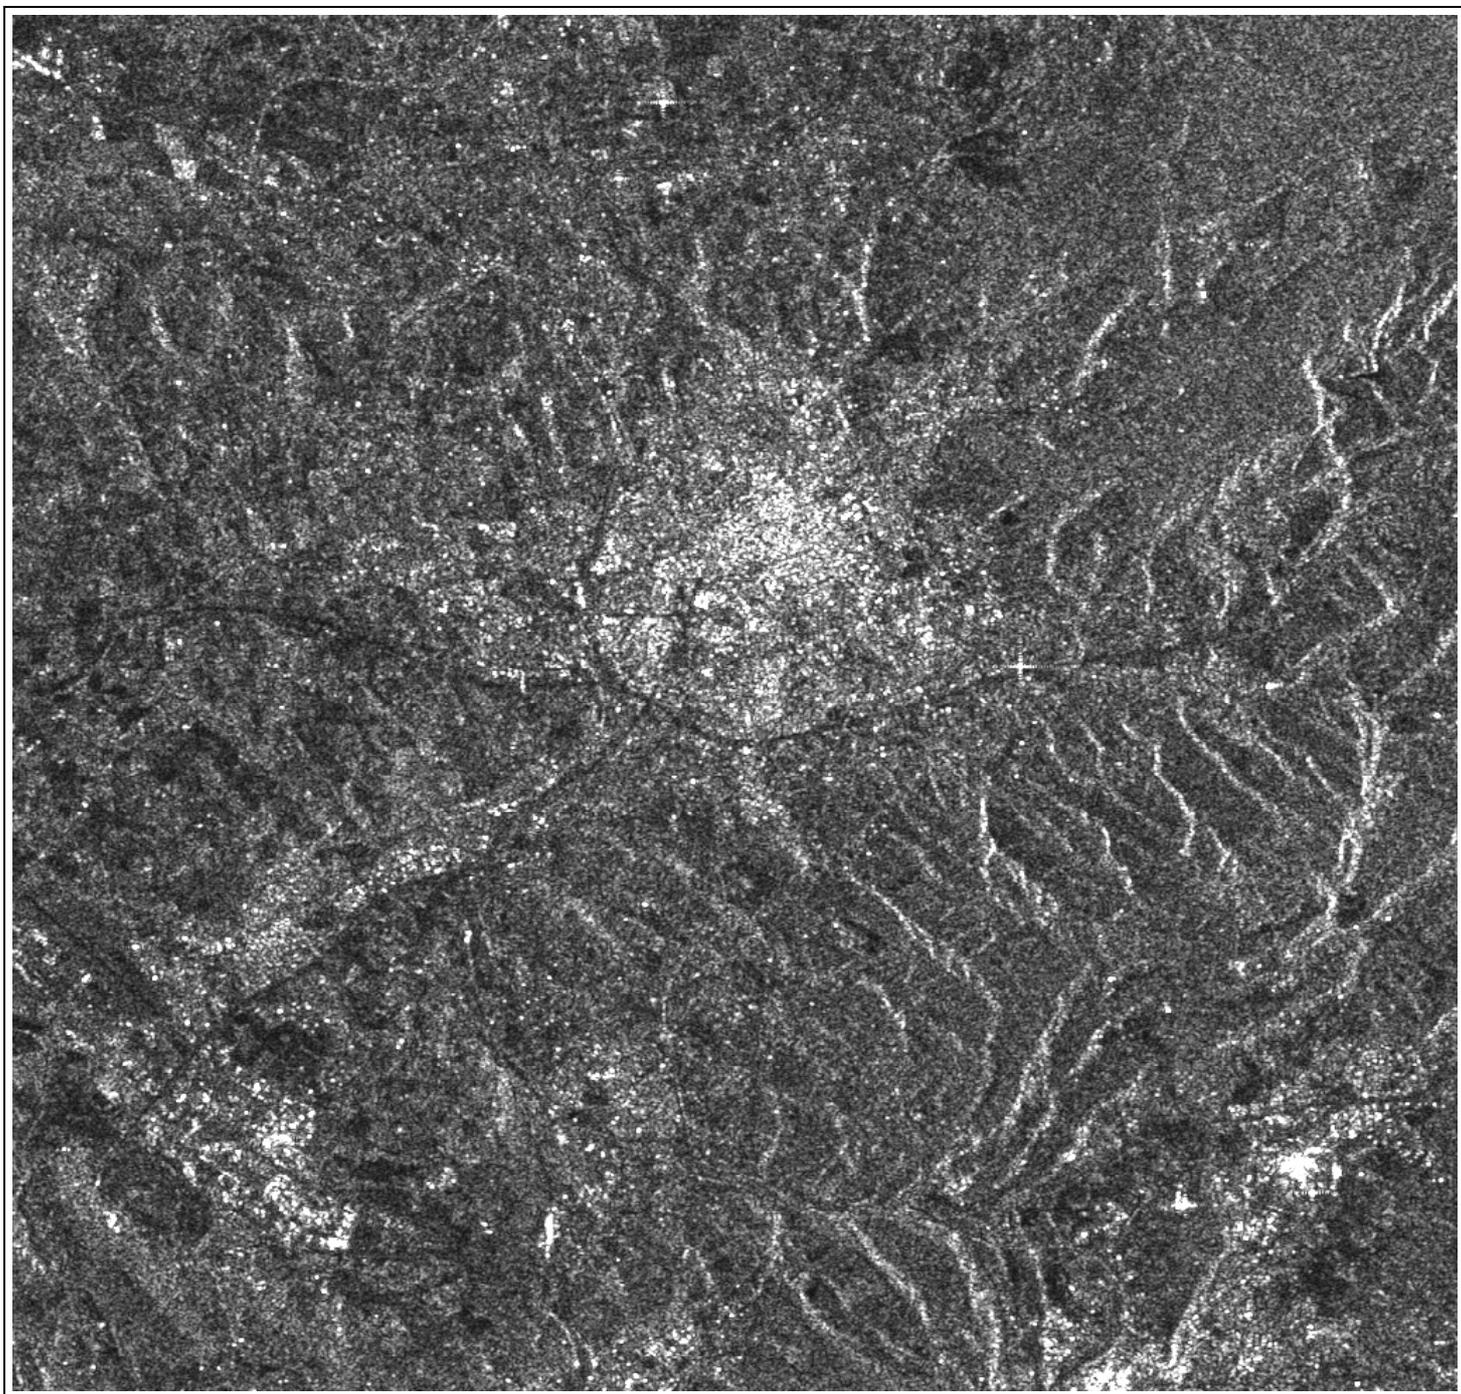


FIG. A.12 – *Image originale d'Aix-en-Provence* ©ESA.



FIG. A.13 – Carte ©Michelin correspondant à l'image d'Aix-en-Provence.

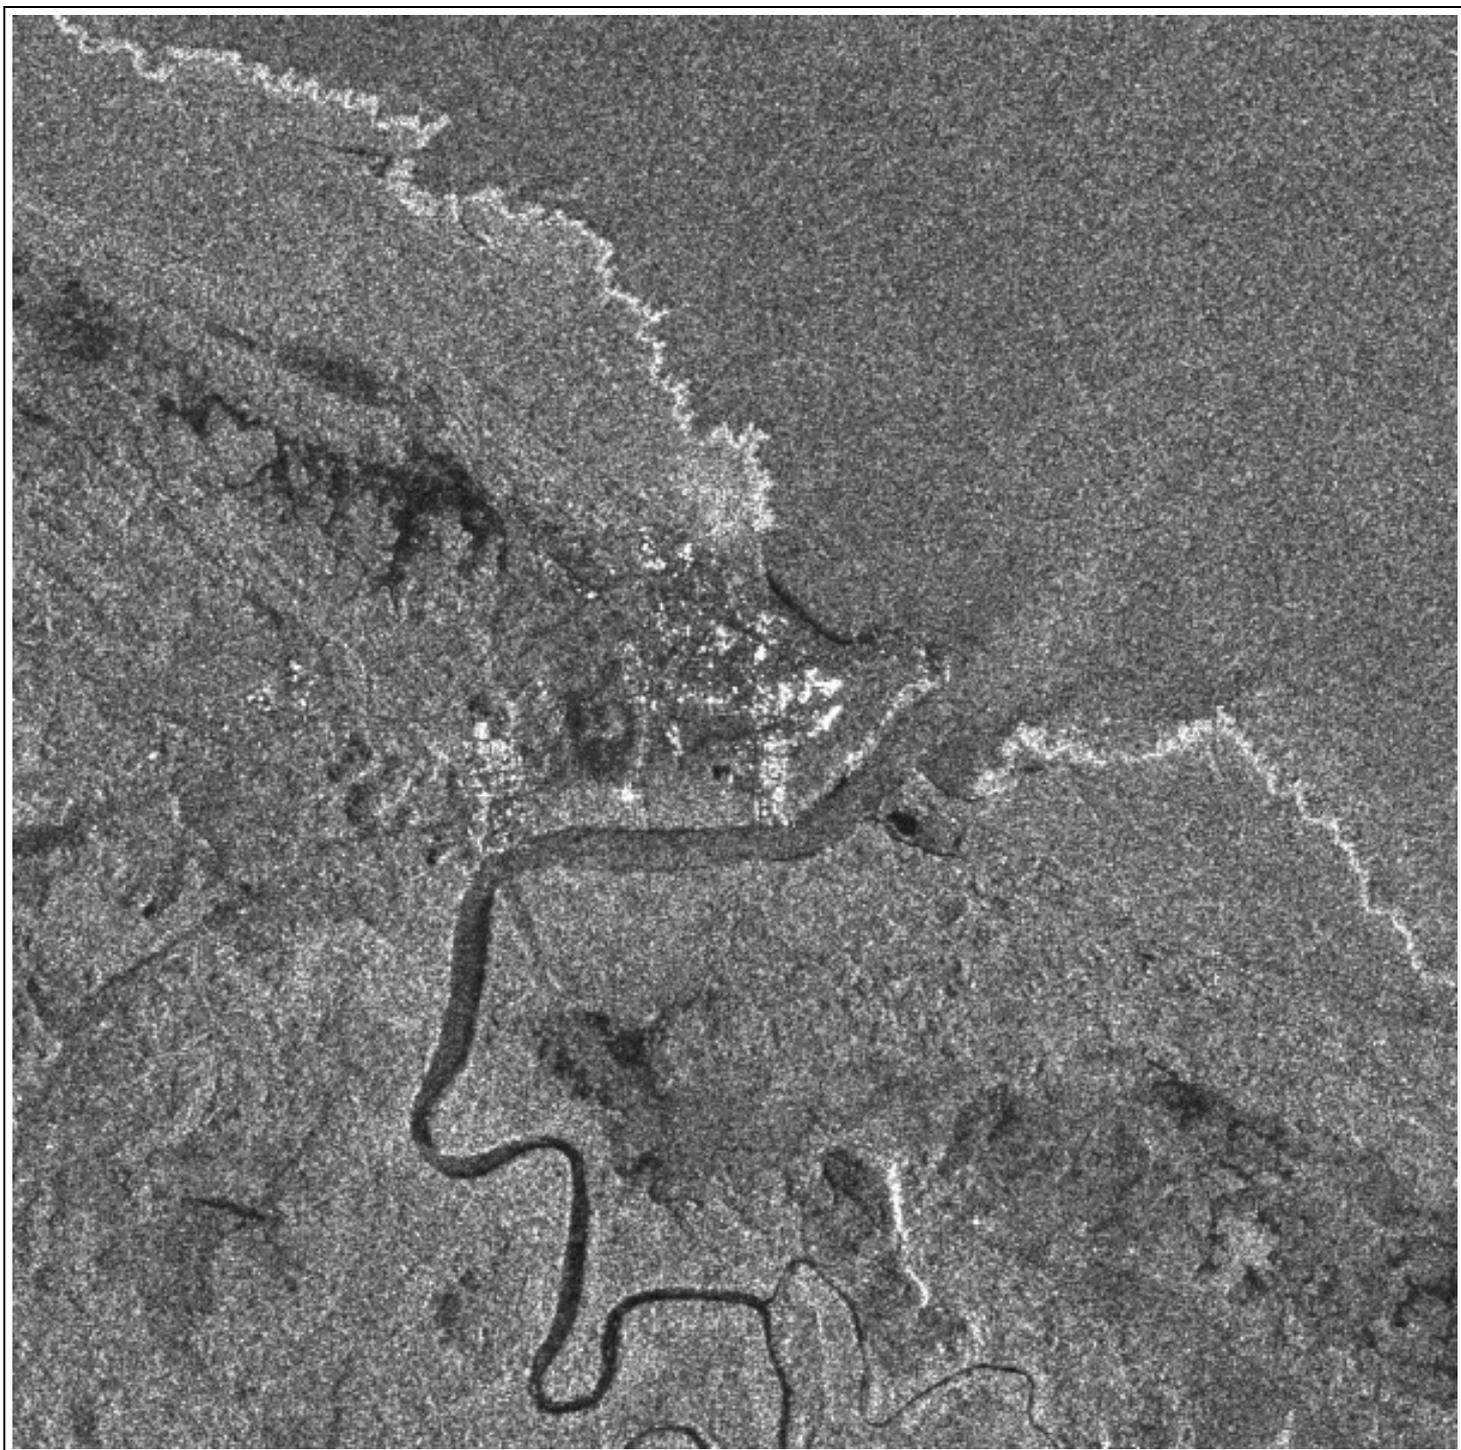


FIG. A.14 – *Image originale de Kourou* ©ESA.

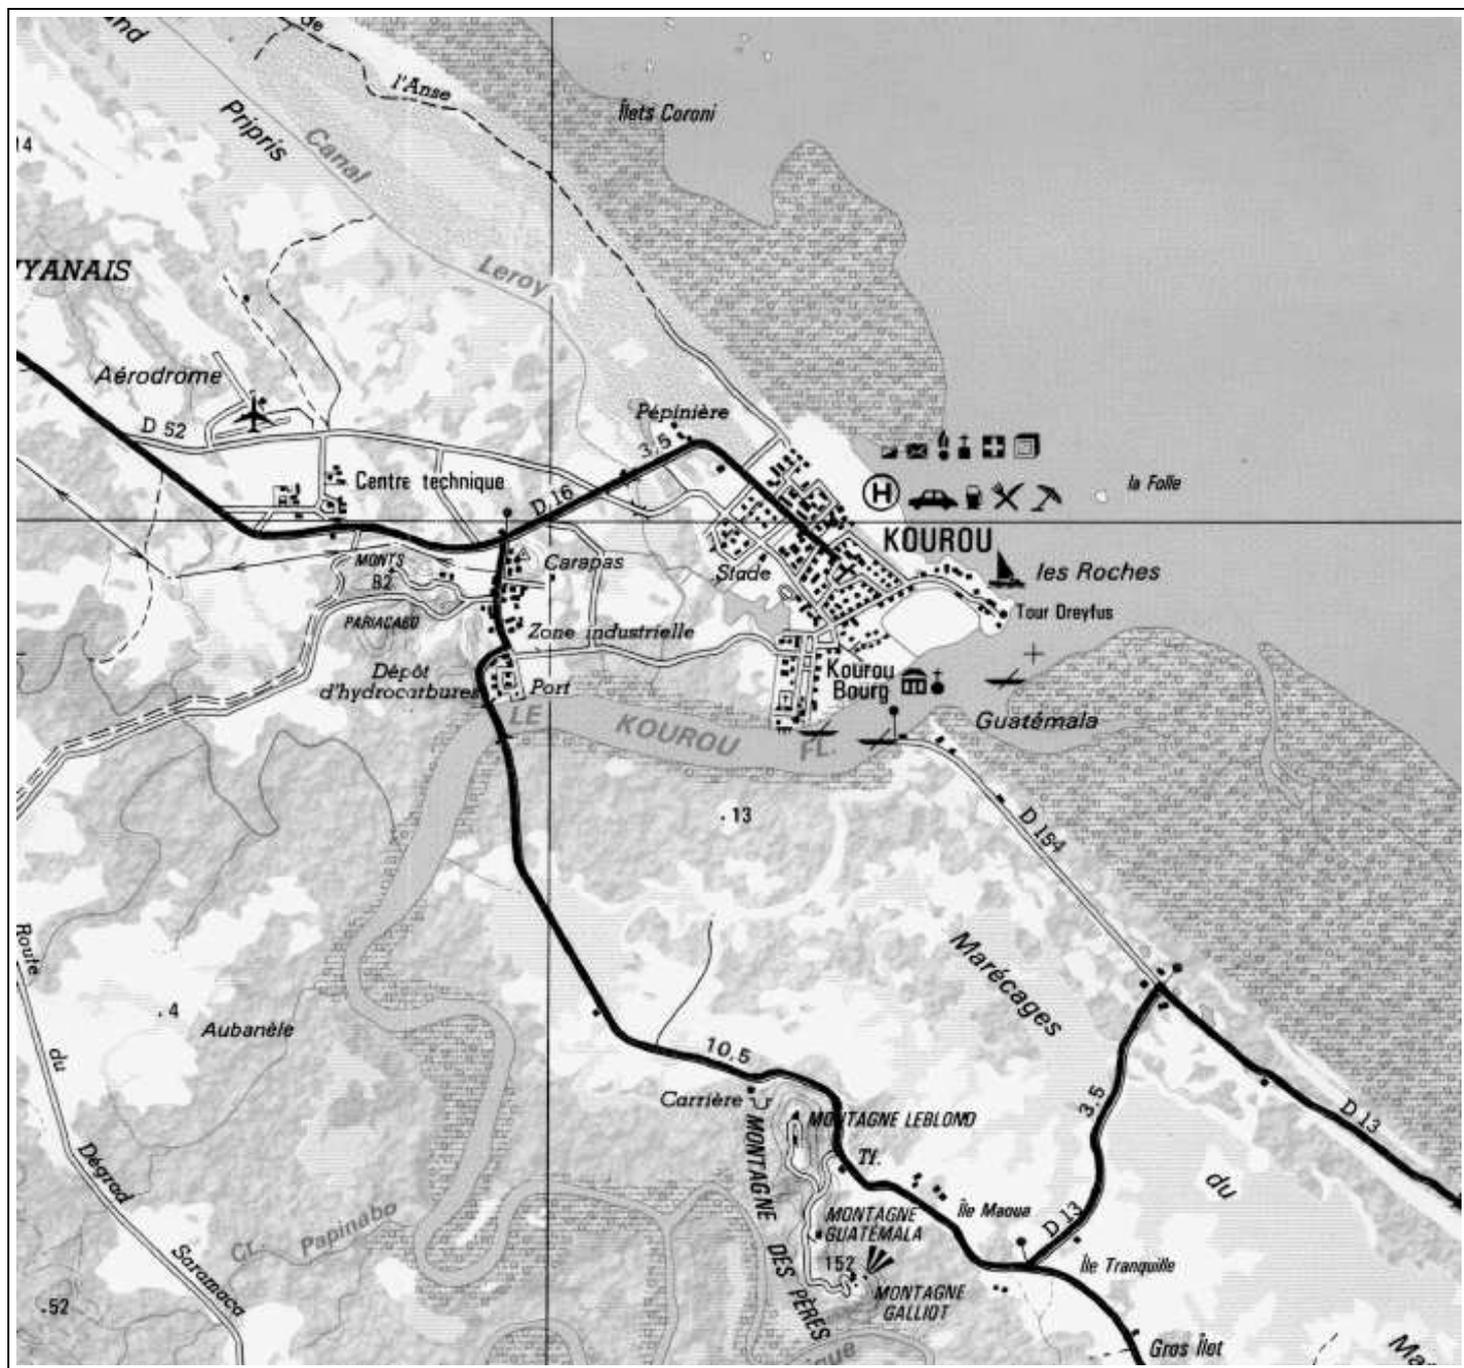


FIG. A.15 – Carte ©IGN correspondant à l'image de Kourou.

## Annexe B

# Appariement de zones urbaines

*L'objectif de cette seconde annexe est de présenter une étude préliminaire des possibilités de recalage automatique entre images radars et cartes. Nous décrivons ici les premières expérimentations effectuées pour mettre en correspondance les zones urbaines extraites d'une image radar d'une part et d'une carte d'autre part. La méthode utilisée est une méthode par génération et propagation d'hypothèses déjà appliquée au recalage carte / image SPOT [Roux-92]. La transformation paramétrée déduite permet d'obtenir un recalage grossier entre les deux images qui pourrait servir de base à des travaux ultérieurs.*

### B.1 Introduction

Il serait particulièrement utile de pouvoir recalculer automatiquement les vues prises par des capteurs différents pour plusieurs applications cartographiques (mise à jour, comparaison multi-vues, etc.). Bien qu'en l'absence de MNT, cet objectif soit voué à l'échec sur les images radar en zone de relief sur lesquelles les déformations géométriques sont très importantes, il est intéressant de recalculer grossièrement les images pour faciliter la tâche d'un photo-interprète. Nous décrivons ici des travaux préliminaires sur le recalage automatique entre une image radar et une carte. La section suivante décrit le principe de la méthode utilisée tandis que la troisième section présente l'extraction des primitives sur les images radar et sur les cartes. Enfin les résultats obtenus sur les images de Mantes-La-Jolie, de Lorient et d'Aix-en-Provence sont analysés.

### B.2 Méthode utilisée

Nous avons repris une partie des travaux effectués par M. Roux lors de sa thèse [Roux-92] sur le recalage automatique entre une image SPOT et une carte. La démarche adoptée était d'effectuer le recalage en deux étapes : une première étape globale qui mettait en correspondance certaines primitives de haut-niveau extraites dans les deux images (zones urbaines, carrefours), puis une étape locale qui calculait pour chaque appariement de carrefours un point d'amer précis en utilisant les segments constituant ces carrefours. Nous proposons

dans cette annexe de reprendre l'étape globale pour mettre en correspondance les agglomérations détectées dans l'image radar et celles extraites de la carte. Le choix de ces primitives, très mal localisées à cause de leur forme complexe, implique que le recalage obtenu sera nécessairement très grossier. Notre objectif se limite donc à une identification des zones urbaines de l'image radar par association aux zones urbaines de la carte.

Les primitives associées aux agglomérations sont des disques de même surface que la région de l'image et de centre le centre de gravité de cette région. Chaque agglomération est donc représentée par  $v_i = (p_i, r_i)$  où  $p_i$  est le centre du disque et  $r_i$  son rayon. Ce mode de représentation n'est certes pas idéal lorsque les formes des agglomérations sont fines et ramifiées mais il est suffisant pour l'objectif que nous nous sommes fixés dans un premier temps. Nous noterons  $S_{\mathcal{R}}$  l'ensemble des primitives extraites de l'image radar et  $S_{\mathcal{C}}$  l'ensemble des primitives extraites de la carte (l'extraction des primitives proprement dite est décrite dans le paragraphe suivant). Par ailleurs, pour tout sous-ensemble de primitives  $P_{\mathcal{R}}$  de l'image radar et le sous-ensemble de primitives leur correspondant  $P_{\mathcal{C}}$  de la carte, on peut définir l'ensemble  $A$  des appariements entre ces primitives :

$$A = \{a/a = (r, c), r \in P_{\mathcal{R}}, c \in P_{\mathcal{C}}\}$$

$\mathcal{R}$  représente l'espace euclidien lié à l'image radar, et  $\mathcal{C}$  celui lié à la carte ; les coordonnées des points dans ces deux espaces sont notées respectivement  $p_{\mathcal{R}} = (x_{\mathcal{R}}, y_{\mathcal{R}})$  et  $p_{\mathcal{C}} = (x_{\mathcal{C}}, y_{\mathcal{C}})$ .

La méthode développée par M. Roux repose sur le principe de la génération et propagation d'hypothèses. La contrainte principale de cette méthode est que la déformation entre les deux images à recaler appartienne à une famille de transformations paramétrées. Nous allons considérer ici une déformation globale, c'est-à-dire représentée par une seule transformation entre les deux images. Cette hypothèse est peu adaptée à notre problème, notamment sur les zones de relief pour lesquelles il serait plus approprié de découper l'image et d'envisager plusieurs transformations suivant les différentes zones considérées. Nous allons néanmoins et dans cette étude préliminaire nous limiter à des transformations globales polynomiales, donc pour un degré  $n$  et pour un passage de l'image radar à la carte, c'est-à-dire de  $\mathcal{R}$  à  $\mathcal{C}$ , de la forme :

$$\begin{aligned} x_{\mathcal{C}} &= \sum_{i=0}^n \sum_{j=0}^{n-i} a_{ij} x_{\mathcal{R}}^i y_{\mathcal{R}}^j \\ y_{\mathcal{C}} &= \sum_{i=0}^n \sum_{j=0}^{n-i} b_{ij} x_{\mathcal{R}}^i y_{\mathcal{R}}^j \end{aligned}$$

Le degré de la transformation est choisi ici égal à 1, c'est à dire que nous considérons des transformations affines du plan :

$$\begin{aligned} x_{\mathcal{C}} &= a_1 x_{\mathcal{R}} + a_2 y_{\mathcal{R}} + a_3 \\ y_{\mathcal{C}} &= b_1 x_{\mathcal{R}} + b_2 y_{\mathcal{R}} + b_3 \end{aligned}$$

Notons  $\Phi$  la famille des transformations affines de  $\mathcal{R}$  dans  $\mathcal{C}$ . Connaissant un ensemble d'appariements entre l'image radar et la carte, il est possible de déduire la transformation

affine qui permet de passer de l'une à l'autre, par exemple en choisissant la transformation  $\phi$  qui minimise l'erreur quadratique moyenne entre les transformés des points de  $\mathcal{R}$  et les points de  $\mathcal{C}$  qui leur sont associés. Formellement, pour un ensemble  $A$  d'appariements, on cherche la transformation  $\phi_A$  qui minimise  $\Sigma$  :

$$\Sigma = \sum_{a=(r,c) \in A} \text{dist}^2(\phi(r), c)$$

Il existe toujours une application affine  $\phi_A$  qui résolve le problème selon le critère de l'erreur quadratique moyenne si et seulement si il existe au moins trois points non-alignés de l'image radar dans l'ensemble des appariements.

Puisque nous savons déterminer la transformation minimisant l'erreur quadratique moyenne à partir d'un ensemble d'appariements donné, le problème est ramené à la recherche du meilleur ensemble d'appariements possible au sens d'un coût donné. Soit  $A$  un ensemble d'appariements et soit  $\phi_A$  la transformation affine qui minimise l'erreur quadratique moyenne, nous définissons le coût  $C_A$  associé à cette transformation par la somme des deux coûts  $C_A^1$  et  $C_A^2$  suivants :

- le premier coût dépend directement de l'erreur quadratique moyenne liée à la transformation, divisée par le nombre d'appariements de  $A$  pour favoriser le plus grand nombre d'appariements possibles :

$$C_A^1 = \frac{1}{\text{card}(A)} \sum_{a=(r,c) \in A} \text{dist}^2(\phi_A(r), c)$$

- le second coût favorise un grand nombre d'appariements en pénalisant les agglomérations de l'image radar qui n'ont pas été appareillées de façon proportionnelle à leur taille :

$$C_A^2 = \frac{1}{\text{card}(A)} \sum_{a=(r,c) \in A} r_r^2$$

(où  $r_r$  est la rayon de l'agglomération  $r$  de l'image radar).

Notons que la carte et l'image radar ne jouent pas ici des rôles symétriques. En particulier la pénalisation prise en compte dans  $C_A^2$  porte sur les agglomérations de l'image radar qui ne sont pas appareillées et non sur celles de la carte. Nous avons choisi ce coût en tenant compte du fait que la détection des agglomérations dans l'image radar (voir section suivante) est peu sujette aux fausses détections (donc toutes les agglomérations devraient être appareillées si on considère que la détection de la carte est fiable), mais en revanche susceptible de plusieurs omissions (donc plusieurs agglomérations de la carte peuvent ne pas être appareillées). Il est donc cohérent de pénaliser le non appareillement des agglomérations de l'image radar et de ne pas tenir compte de celui des agglomérations de la carte.

De plus, il est important que ce second coût soit défini en fonction du rayon, donc de la taille des agglomérations. Les grosses zones urbaines sont en effet généralement bien détectées sur l'image radar sous forme d'amas de points brillants très denses et il est donc indispensable qu'elles soient appareillées avec des agglomérations de la carte pour que la transformation obtenue soit correcte.

Ayant défini le coût qui sera considéré pour évaluer la qualité d'un ensemble d'appareillement  $A$ , il reste à développer une stratégie pour déterminer cet ensemble. La solution utilisée par M. Roux repose sur le principe de génération et propagation d'hypothèses [Roux-92]:

- Génération : une première transformation est déterminée à l'aide d'un petit nombre de points d'amer ; en fait la transformation utilisée pour initialiser le processus est une similitude et seuls deux points d'amer sont suffisants pour la définir ; cette transformation  $\phi_0$  va permettre de définir de nouveaux points d'amer en acceptant les couples  $(r, c)$  pour lesquels  $\text{dist}(\phi_0(r), c) < D$  où  $D$  est une distance seuil définie par l'utilisateur (par exemple une distance de 50 pixels).
- Propagation: le nouvel ensemble d'amers ainsi défini permet de déduire une nouvelle transformation (affine cette fois-ci) minimisant l'erreur quadratique moyenne. De nouveaux amers sont éventuellement acceptés en utilisant le même critère que précédemment et ce nouvel ensemble d'amers permet d'itérer une nouvelle fois le processus. Les itérations cessent lorsque la convergence est atteinte. Le coût associé à la transformation finale est alors calculé.
- Décision : parmi toutes les générations qui ont été propagées le résultat est donné par la transformation de coût minimal.

Plusieurs heuristiques sont utilisées pour limiter le temps de calcul en réduisant le domaine de génération par des paramètres initialisant la transformation et celui de propagation en détectant les configurations déjà rencontrées [Roux-92].

## **B.3 Détection des agglomérations dans l'image radar et dans la carte**

Cette section décrit brièvement les traitements qui nous ont permis d'extraire les agglomérations sur l'image radar et sur la carte. Les trois zones traitées sont centrées sur les villes de Mantes-la-Jolie (§A.4), Lorient (§A.3) et Aix-en-Provence (§A.5) sur lesquelles les zones urbaines sont suffisamment nombreuses.

### **B.3.1 Détection des agglomérations de l'image radar**

La détection se fait simplement en utilisant les résultats de la classification finale présentée au chapitre 8. Les zones classées *ville* ou *industriel* sont extraites et quelques opérations de morphologie mathématique (ouverture et fermeture) sont appliquées pour les régulariser (fig. B.1).

### **B.3.2 Détection des agglomérations de la carte**

Les cartes utilisées sont des cartes Michelin au 1 :200 000 (Bretagne fig.B.3 et Provence Côte d'Azur fig.B.4) et au 1 :100 000 pour les Environs de Paris fig.B.2 qui ont été scannées en couleur à une résolution de 600 dpi et ont une taille de l'ordre de 1200 sur 1200 pixels.



FIG. B.1 – Agglomérations détectées sur les images ROS de Mantes-La-Jolie, de Lorient et d'Aix-en-Provence, de gauche à droite respectivement.

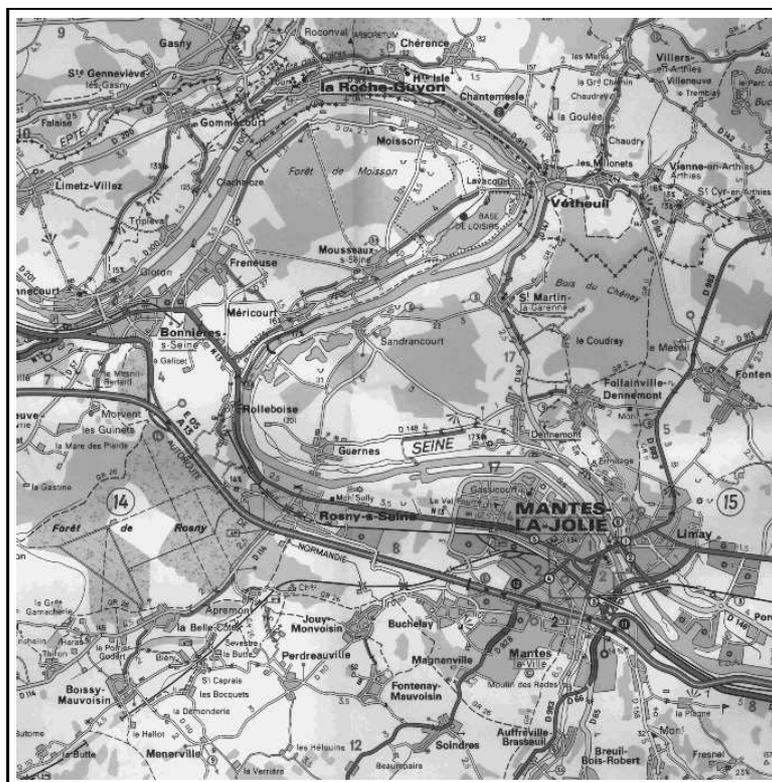


FIG. B.2 – Carte Michelin sur Mantes-La-Jolie au 1:100 000 ©Michelin

- **carte au 1/100 000** : le traitement de cette carte a pu se faire de façon relativement automatique puisque les zones urbaines apparaissent sous forme de zones oranges et grises pour les zones industrielles. Des traitements simples dans l'espace des couleurs RVB permettent de sélectionner les zones de ces couleurs qui sont ensuite là encore régularisés par des opérations de morphologie mathématique.

- **carte au 1/200 000** : elles sont moins adaptées pour le problème qui nous préoccupe et leur traitement est moins facile car si les plus grandes zones urbaines sont indiquées en gris, les plus petites en revanche apparaissent sous forme d'amas de petits blocs noirs qu'il

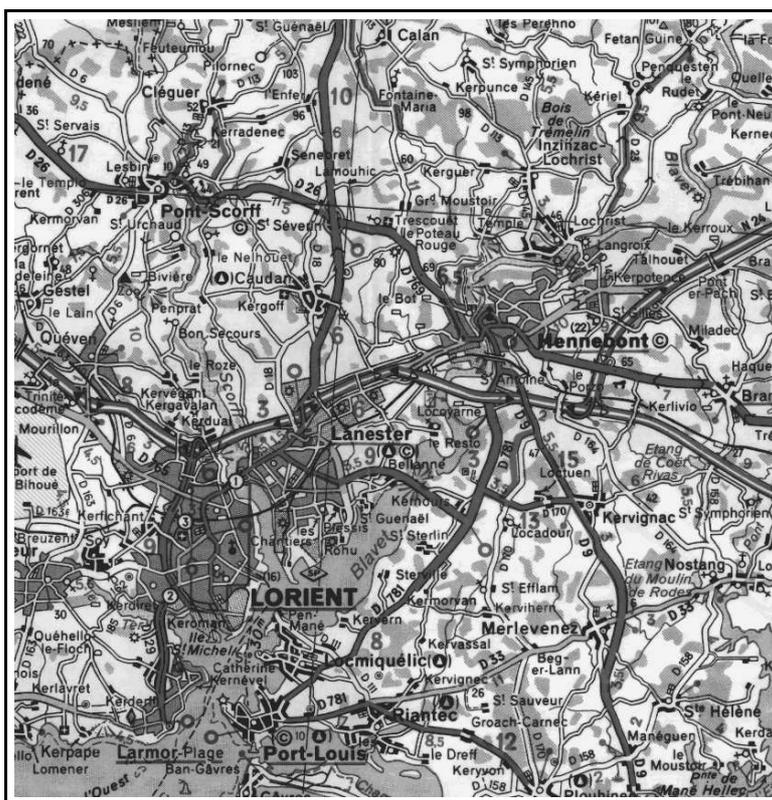


FIG. B.3 – Carte Michelin sur Lorient au 1 : 200 000 ©Michelin

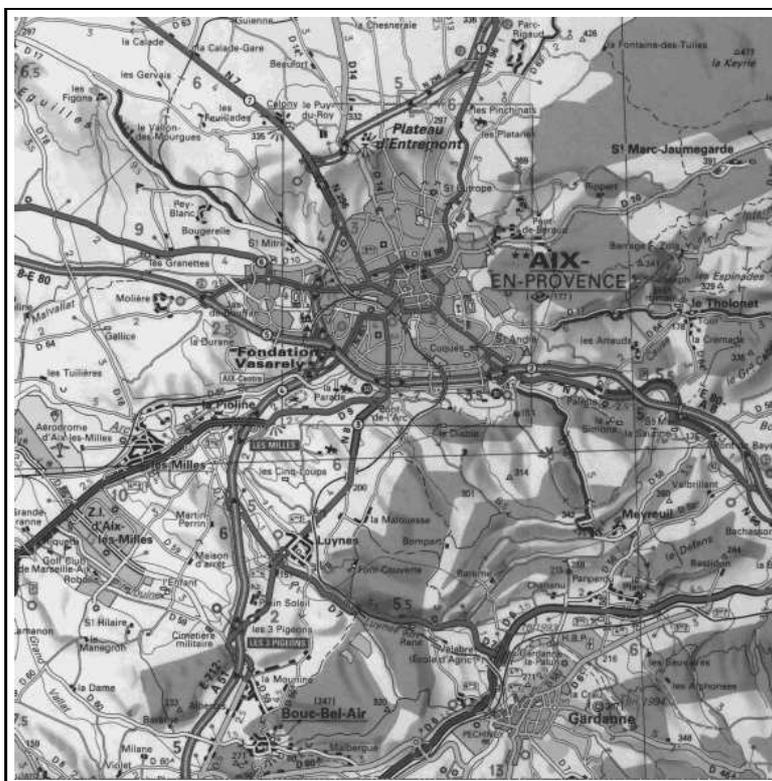


FIG. B.4 – Carte Michelin sur Aix-en-Provence au 1 : 200 000 ©Michelin

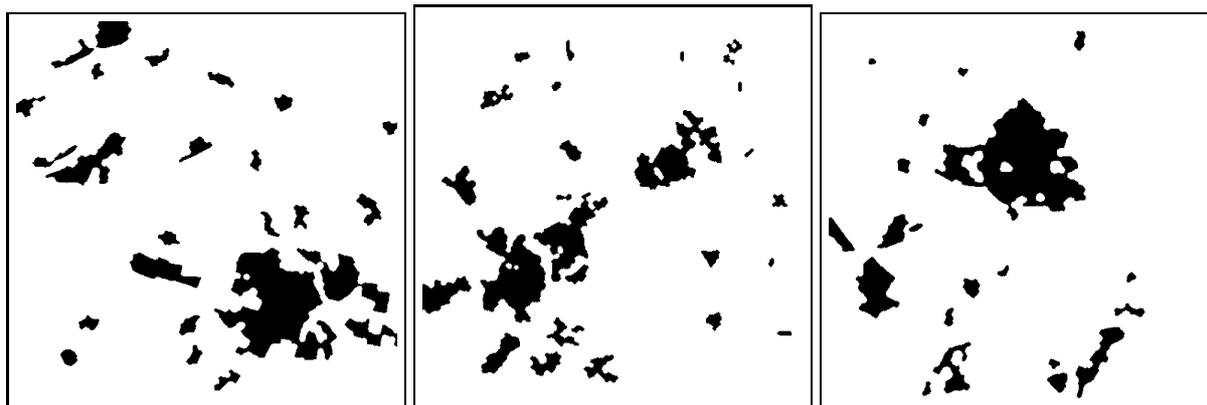


FIG. B.5 – Agglomérations détectées sur les cartes de Mantes-La-Jolie, de Lorient et d'Aix-en-Provence, de gauche à droite respectivement.

est plus difficile de détecter automatiquement. En effet, des confusions avec les lettres ou d'autres signes indicatifs sont possibles. Par manque de temps pour mettre au point une méthode de traitement automatique qui sort du cadre de notre travail, nous avons utilisé un logiciel interactif écrit par Michel Roux qui permet à l'utilisateur de sélectionner des composantes connexes préalablement détectées. Là encore des opérations de morphologie mathématique ont permis un regroupement des régions entre elles pour former des zones urbaines de tailles suffisantes.

Les résultats pour les trois cartes traitées sont montrés sur la figure B.5.

## B.4 Résultats de recalage par mise en correspondance des agglomérations

Les agglomérations extraites des images radar et des cartes fournissent des primitives sous forme de disques définis par leur rayon et leur centre. Le coefficient d'homothétie approximatif fourni en entrée est de 1 pour les cartes Michelin au 1 :100 000, et de 0,5 pour la carte au 1 :200 000. La distance seuil à partir de laquelle un nouveau point d'amer est accepté est de 50 pixels.

### B.4.1 Image de Mantes

Le résultat obtenu est présenté sur la figure B.6. Si la plupart des zones urbaines de l'image radar sont bien associées à l'agglomération de la carte qui leur correspond, le recalage obtenu est néanmoins grossier et certaines régions appareillées sont nettement décalées (Sandrancourt, Dennemont, Rosny-sur-Seine). L'axe routier et le fleuve passant à l'intérieur de Mantes-La -Jolie sont décalés vers le bas, à cause de l'utilisation des centres de gravité qui ne sont pas bien localisés. Certaines formes, de Freneuse et Bonnières-sur-Seine, Rosny-sur-Seine, ou Garny sont bien détectées et mériteraient d'être conservées pour le recalage. D'une façon générale, la transformation qui a été obtenue en utilisant seulement les aggro-

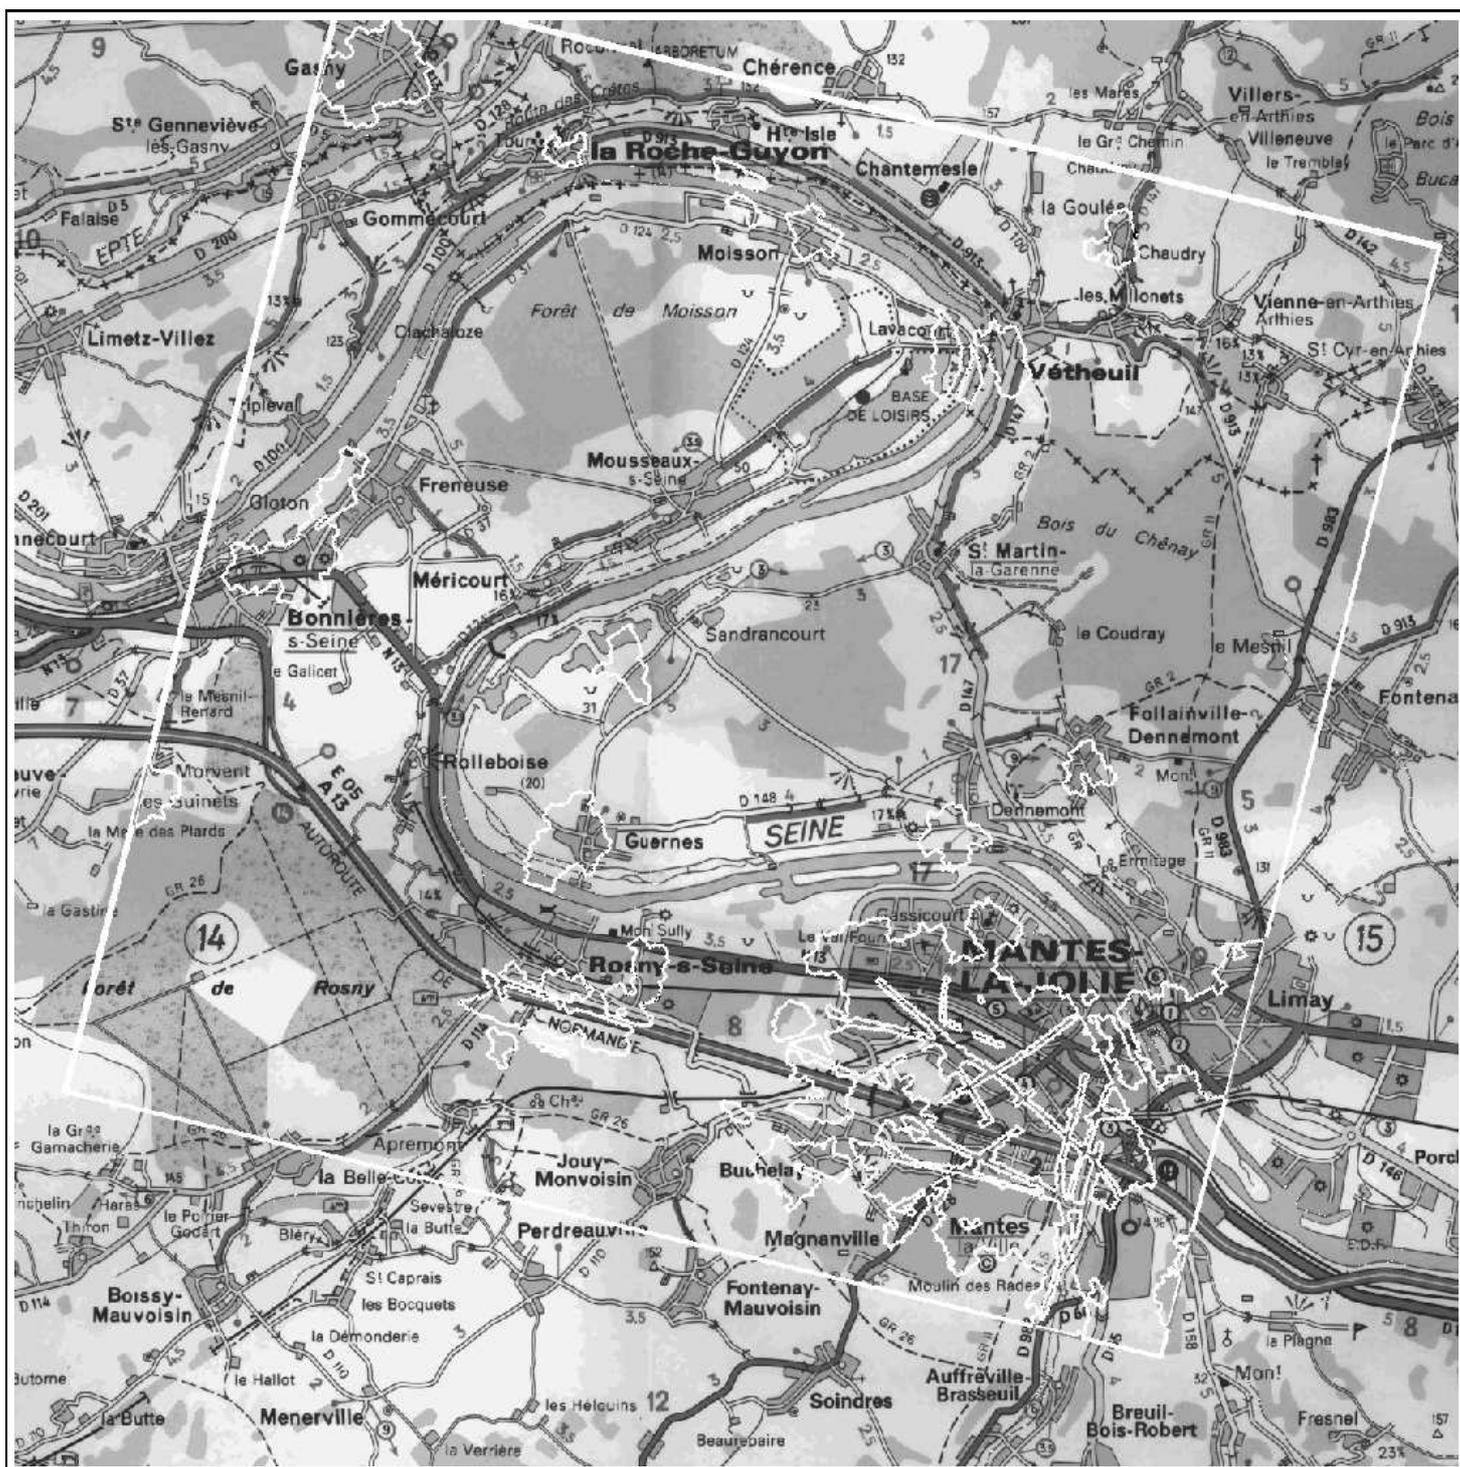


FIG. B.6 – Superposition des zones urbaines de l'image radar et de ses bords (en blanc) après application de la transformation de recalage sur la carte pour l'image de Mantes-La-Jolie.

mérations pourrait servir d'initialisation à un recalage plus fin s'appuyant sur des primitives mieux localisées.

### **B.4.2 Image de Lorient**

Le résultat obtenu est présenté sur la figure B.7. Les remarques faites précédemment restent valables même si le recalage semble un peu plus précis pour les petites agglomérations comme Kaudan, Kervignac et Lochrist. La détection de la route au niveau de Lanester ou du bras de la rivière Scorff sont également dans l'axe mais les formes des zones détectées sur l'image radar ne correspondent pas bien à celles de la carte pour les grosses agglomérations. Là encore, la transformation obtenue permet d'initialiser un recalage plus fin.

### **B.4.3 Image d'Aix-en-Provence**

Les résultats sont moins satisfaisants que ceux obtenus précédemment (fig. B.8). Si Aix-en-Provence semble bien recalée puisque les axes routiers qui traverse la zone urbaine correspondent en partie à ceux de la carte, la zone industrielle des Mines est recalée de façon très imprécise tout comme la région entre Gardannes et Meyreuil. L'agglomération de Luynes est décalée vers le bas, comme l'indique le passage de l'axe routier, et l'agglomération de Parc-Rigaud en haut de l'image est beaucoup trop à gauche. Ce mauvais recalage a plusieurs causes : tout d'abord les fortes déformations géométriques sur l'image radar dues à la présence importante de relief sur la droite de l'image ; ensuite l'inadaptation de la résolution de la carte à notre objectif puisque les petites zones urbaines ne sont pas bien indiquées et plusieurs petites régions industrielles n'ont pas pu être utilisées ; enfin, l'imprécision des formes des zones urbaines détectées sur l'image radar, trop de régions industrielles distinctes étant agglomérées en une seule.

## **B.5 Conclusion**

Nous avons présenté dans cette annexe les résultats d'une étude préliminaire pour le recalage automatique entre une carte et une image radar. Une méthode de génération et propagation d'hypothèses développée par M. Roux [Roux-92] a été appliquée à la mise en correspondance des agglomérations extraites de l'image radar et de la carte. Si le recalage obtenu avec ces primitives particulièrement mal localisées est grossier il procure néanmoins une bonne initialisation pour la recherche d'un recalage plus fin. Il pourrait également être utilisé pour valider d'autres objets détectés par notre méthode de classification comme les routes.

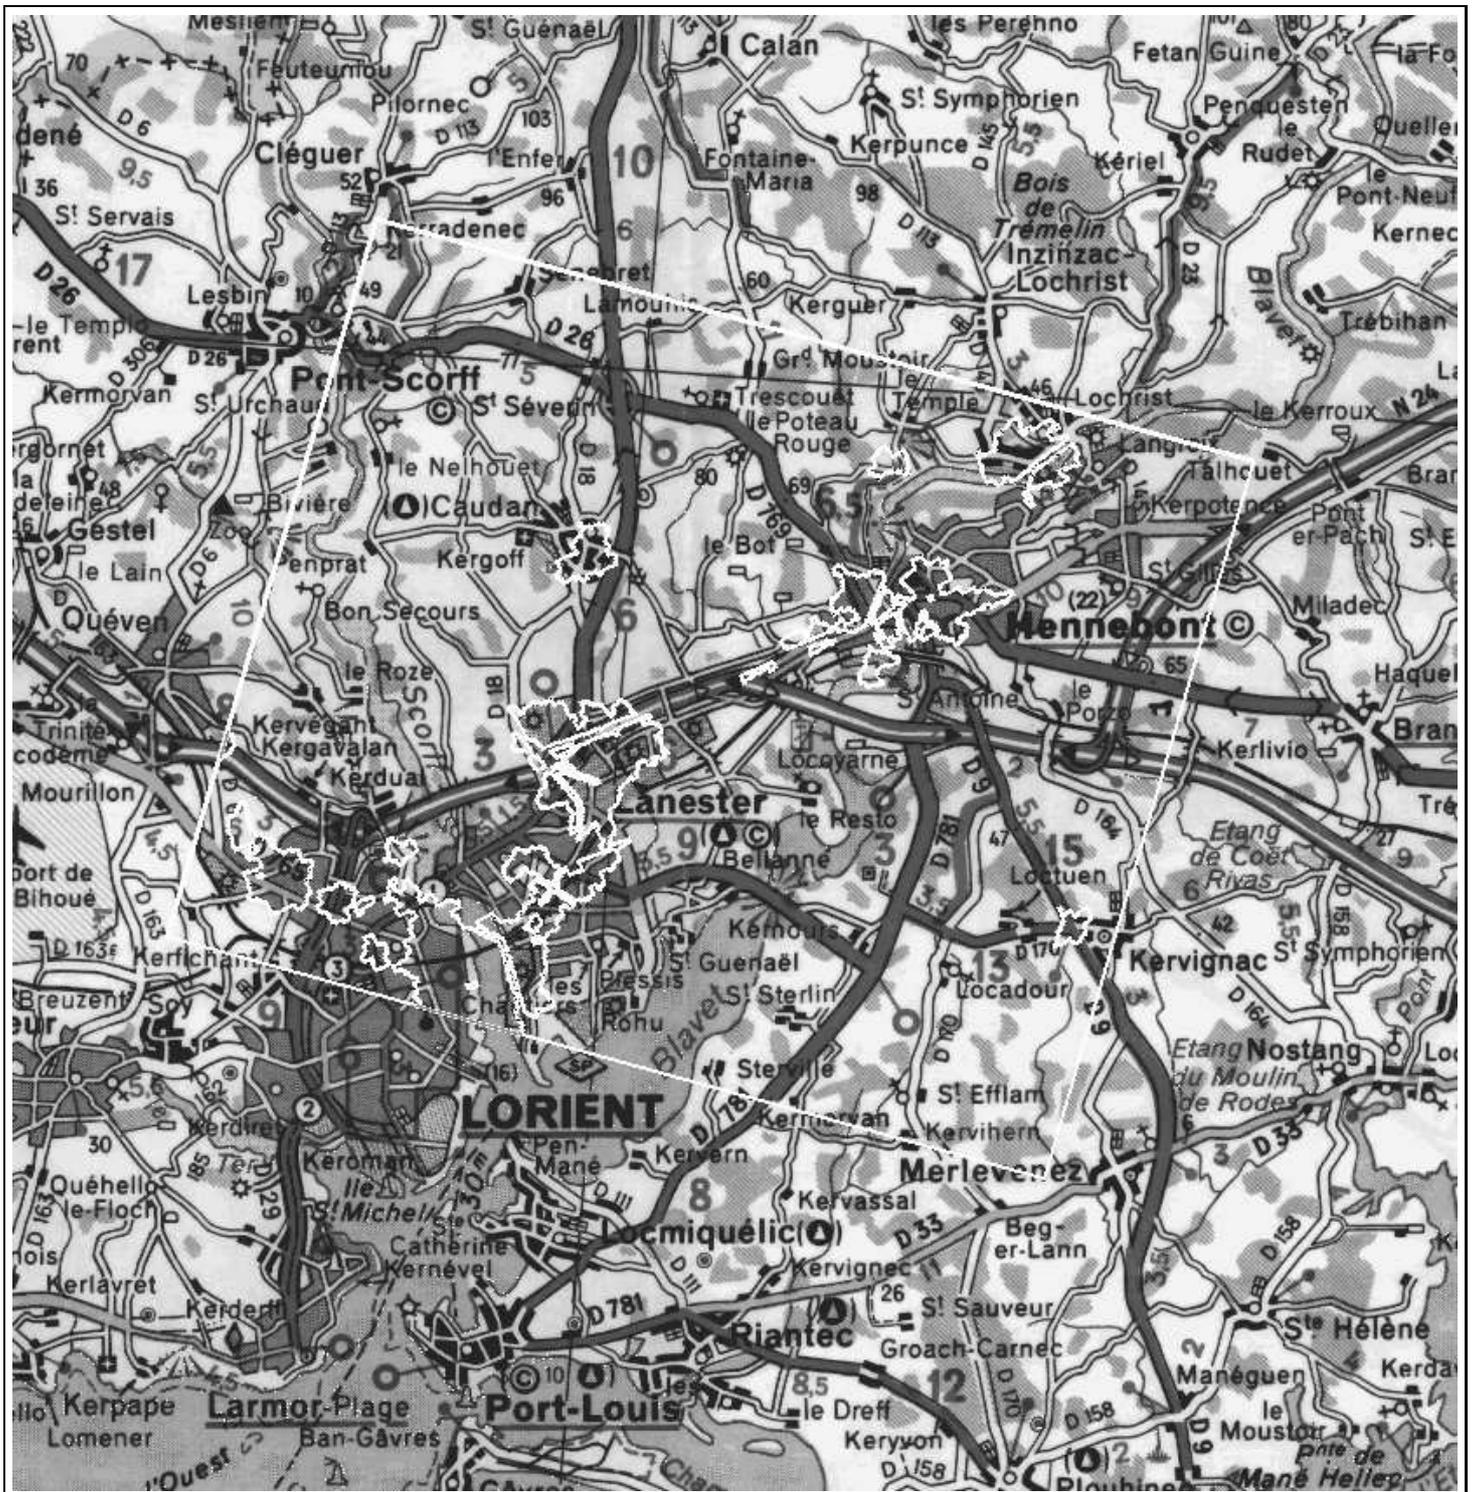


FIG. B.7 – Superposition des zones urbaines de l'image radar et de ses bords (en blanc) après application de la transformation de recalage sur la carte pour l'image de Lorient.



FIG. B.8 – Superposition des zones urbaines de l'image radar et de ses bords (en blanc) après application de la transformation de recalage sur la carte pour l'image d'Aix-en-Provence.

## Bibliographie

- [Abra-72] M. ABRAMOWITZ ET I. STEGUN, *Handbook of Mathematical Functions*, Dover Publications, 1972.
- [Adai-90] M. ADAIR ET B. GUINDON, *Statistical edge detection operators for linear feature extraction in SAR images*, Canadian Journal of Remote Sensing, 16 (1990), pp. 10–19.
- [Aira-94] S. AIRAULT, R. RUSKONÉ, ET O. JAMET, *Road detection from aerial images: a cooperation between local and global methods*, Image and Signal Processing for Remote sensing, 2315 (1994), pp. 508–518. .
- [Andr-88] K. M. ANDRESS ET A. C. KAK, *Evidence accumulation and flow control in a hierarchical spatial reasoning system*, AI Magazine, (1988), pp. 75–94.
- [Ardu-92] F. ARDUINI, C. DAMBRA, ET C. S. REGAZZONI, *A coupled MRF model for SAR image restoration and edge-extraction*, IGARSS'92 (Houston), 2 (1992), pp. 1120–1122.
- [Arse-84] H. H. ARSENAULT ET M. LEVESQUE, *Combined homomorphic and local statistics processing for restoration of images degraded by signal-dependent noise*, Applied Optics, 23 (1984), pp. 845–850.
- [Arse-86] H. H. ARSENAULT ET G. V. APRIL, *Information content of images degraded by speckle noise*, Optical Engineering, 25 (1986), pp. 662–666.
- [Ayan-71] Y. AYANT ET M. BORG, *Fonctions spéciales à l'usage des étudiants en physique*, Dunod université, 1971.
- [Azen-92a] R. AZENCOTT ET C. GRAFFIGNE, *Non supervised segmentation using multi-level markov random fields*, ICPR, The Hague, Netherlands, (1992).
- [Azen-92b] R. AZENCOTT, *Markov field approach: parameter estimation by qualitative boxes*, Cours : Les Houches, (1992).
- [Bara-96] A. BARALDI ET F. PARMIGGIANI, *Segmentation of SAR images by means of Gabor filters working at different spatial resolution*, IGARSS'96 (Lincoln, Nebraska, USA), III (1996), pp. 709–713.

- [Barb-85] B. C. BARBER, *Theory of digital imaging from orbital synthetic aperture radar*, International Journal of Remote Sensing, 6 (1985), pp. 1009–1057.
- [Barb-93] D. G. BARBER, M. E. SHOKR, R. A. FERNANDES, E. D. SOULIS, D. G. FLETT, ET E. F. LEDREW, *A comparison of second-order classifiers for SAR sea ice discrimination*, Photogrammetric Engineering and Remote Sensing, 59 (1993), pp. 1397–1408.
- [Barn-81] J. A. BARNETT, *Computational methods for a mathematical theory of evidence*, Proc. of the Seventh International Joint Conference on Artificial Intelligence, Vancouver, (1981), pp. 868–875.
- [Barn-91] ———, *Calculating dempster-shafer plausibility*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 13 (1991), pp. 599–602.
- [Barz-96] M. BARZOHAR ET D. B. COOPER, *Automatic finding of main roads in aeriels images by using geometric stochastic models and estimation*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-18 (1996), pp. 707–721.
- [Beau-92] A. BEAUPÈRE, *Classification d'images de radar par mesure de texture*, Thèse de doctorat, Université de Paris VI, 1992.
- [Beauc-96] M. BEAUCHEMIN, K. P. B. THOMSON, ET G. EDWARDS, *The ratio of the arithmetic to the geometric mean : A first-order statistical test for multilook SAR image homogeneity*, IEEE Transactions on Geoscience and Remote Sensing, 34 (1996), pp. 604–606.
- [Bedi-94] L. BEDINI, I. GERACE, ET A. TONAZZINI, *A deterministic algorithm for reconstructing images with interacting discontinuities*, Graphical Models and Image Processing, 56 (1994), pp. 109–123.
- [Berg-91] M.-O. BERGER, *Les contours actifs : modélisation, comportement et convergence*, Thèse de doctorat, Institut National Polytechnique de Lorraine (Nancy), 1991.
- [Bert-88] M. BERTHOD ET M. SERENDERO, *Extraction of thin networks on satellite imagery*, in 9th International Conference on Pattern Recognition (Rome, Italy), 1988, pp. 456–458.
- [Bijn-97] D. BIJNO, *Detection of cerebral pathologies with automatic methods based on fuzzy learning and data fusion*, rapp. tech., Ecole Nationale Supérieure des Télécommunications, 1997.
- [Binf-82] T. O. BINFORD, *Survey of model-based image analysis systems*, The International Journal of Robotics Research, (1982), pp. 18–64.
- [Blak-87] A. BLAKE ET A. ZISSERMAN, *Visual Reconstruction*, MIT Press, 1987.

- [Bloc-94] I. BLOCH ET H. MAÎTRE, *Fusion de données en traitement d'images : modèles d'information et décisions*, *Traitement du Signal*, 11 (1994), pp. 436–446.
- [Bloc-96] I. BLOCH, *Information combination operators for data fusion : A comparative review with classification*, *IEEE Transactions on Systems, Man and Cybernetics*, SMC-26 (1996), pp. 52–67.
- [Bloc-96b] ———, *Some aspects of Dempster-Shafer evidence theory for classification of multi-modality medical images taking partial volume effect into account*, *Pattern Recognition Letters*, 17 (1996), pp. 905–919.
- [Bloc-97] I. BLOCH ET H. MAITRE, *Fusion of Image Information under Imprecision*, B. Bouchon Meunier Ed. , *Series Studies in Fuzziness*, Physica Verlag, Springer, 1997.
- [Bloc-97b] I. BLOCH, L. AURDAL, D. BIJNO, ET J. MULLER, *Estimation of class membership functions for grey-level based image fusion*, *ICIP'97 (Santa Barbara)*, (1997).
- [Blos-89] D. BLOSTEIN ET N. AHUJA, *Shape from texture : Integrating texture-element extraction and surface estimation*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-11 (1989), pp. 1233–1251.
- [Boum-92] B. A. M. BOUMAN ET D. UENK, *Crop classification possibilities with radar in ERS-1 and JERS-1 configuration*, *Remote Sensing Environment*, 40 (1992), pp. 1–13.
- [Bovi-88] A. C. BOVIK, *On detecting edges in speckle imagery*, *IEEE Transactions on Acoustics, Speech and Signal Processing*, ASSP-36 (1988), pp. 1618–1627.
- [Broo-81] R. BROOKS, *Symbolic reasoning among 3-dimensional models and 2-dimensional images*, *Artificial Intelligence*, 17 (1981), pp. 285–349.
- [Brun-94] J. BRUNIQUEL ET A. LOPES, *Analysis and enhancement of multitemporal SAR data*, *SPIE Europto, Image and Signal Processing of Remote Sensing (Roma, Italy)*, 2315 (1994), pp. 342–353.
- [Brun-96] J. BRUNIQUEL, *Contribution de données multi-temporelles à l'amélioration radiométrique et à l'utilisation d'images de radar à synthèse d'ouverture*, Thèse de doctorat, Université Paul Sabatier (Toulouse), 1996.
- [Burn-81] J. BURNS, A. HUERTAS, ET R. NEVATIA, *Object detection in Synthetic Aperture Radar images*, *Image Understanding Research (Univ. of Southern California)*, (1981), pp. 38–51.
- [Cann-86] J. CANNY, *A computational approach to edge detection*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8 (1986), pp. 679–698.

- [Cari-91] C. CARIOU, *Analyse spectrale d'images numériques Application à la télédétection spatiale des océans*, Thèse de doctorat, Université de Bretagne Occidentale, 1991.
- [Cass-97] D. CASSOU, *Intelligence artificielle et traitement d'image pour la fusion numérique / symbolique et l'interprétation conjointe de cartes numériques et d'images aériennes*.
- [Cave-92] R. G. CAVES, P. J. HARLEY, ET S. QUEGAN, *Matching map features to synthetic aperture radar (SAR) images using template matching*, IEEE Transactions on Geoscience and Remote Sensing, 30 (1992), pp. 680–685.
- [Cave-94] R. G. CAVES ET S. QUEGAN, *Matching segmentation algorithms to ERS1 SAR applications*, SAR Data Processing For Remote Sensing, 2316 (1994), pp. 148–158.
- [Cave-94b] ———, *Segmentation based change detection in ERS-1 SAR images*, IGARSS'94 (Pasadena, California, USA), (1994), pp. 2149–2151.
- [Chal-88] B. CHALMOND, *Image restoration using an estimated Markov model*, Signal Processing, 15 (1988), pp. 115–129.
- [Chal-89] ———, *An iterative Gibbsian technique for reconstruction of m-ary images*, Pattern Recognition, 22 (1989), pp. 747–761.
- [Char-94] P. CHARBONNIER, *Reconstruction d'image : régularisation avec prise en compte des discontinuités*, Thèse de doctorat, Université de Nice Sophia Antipolis, 1994.
- [Chas-91] J.-M. CHASSERY ET A. MONTANVERT, *Géométrie discrète en analyse d'images*, Traité des Nouvelles Technologies, Série Images, Editions Hermès, 1991.
- [Chau-95] S. CHAUVIN, *Evaluation des théories de la décision appliquées à la fusion de capteurs en imagerie satellitaire*, Thèse de doctorat, Université de Nantes, 1995.
- [Chen-93] S.-Y. CHEN, W.-C. LIN, ET C.-T. CHEN, *Evidential reasoning based on Dempster-Shafer theory and its application to medical image analysis*, SPIE, 2032 (1993), pp. 35–46.
- [Chen-96] K. S. CHEN, W. P. HUANG, D. H. TSAY, ET F. AMAR, *Classification of multifrequency polarimetric SAR imagery using a dynamic learning neural network*, IEEE Transactions on Geoscience and Remote Sensing, 34 (1996), pp. 814–820.
- [Chke-95] A. CHKEIF, *Régularisation avec prise en compte des discontinuités : application à la reconstruction d'images*, Rapport de DEA - Université Paris Sud, (1995).

- [Chri-95] W. J. CHRISTMAS, J. KITTLER, ET M. PETROU, *Structural matching in computer vision using probabilistic relaxation*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 17 (1995), pp. 749–764.
- [Clem-93] V. CLEMENT, G. GIRAUDON, S. HOUZELLE, ET F. SANDAKLY, *Interpretation of remotely sensed images in a context of multisensor fusion using a multispecialist architecture*, IEEE Transactions on Geoscience and Remote Sensing, 31 (1993), pp. 779–791.
- [Cley-91] J. V. CLEYNENBREUGEL, S. A. OSINGA, F. FIERENS, P. SUETENS, ET A. OOSTERLINCK, *Road extraction from multi-temporal satellite images by an evidential reasoning approach*, Pattern Recognition Letters, 12 (1991), pp. 371–380.
- [Clou-97] S. R. CLOUDE ET E. POTTIER, *An entropy based classification scheme for land applications of polarimetric SAR*, IEEE Transactions on Geoscience and Remote Sensing, 35 (1997), pp. 68–78.
- [Cohe-92] I. COHEN, *Modèles Déformables 2D et 3D : Application à la Segmentation d'Images Médicales*, Thèse de doctorat, Université Paris IX - Dauphine, 1992.
- [Cook-94] R. COOK, I. M. CONNELL, ET C. OLIVER, *MUM (Merge Using Moments) segmentation for SAR images*, Satellite Remote Sensing I EUROPTO (Rome), 2316 (1994), pp. 92–103.
- [Cox-93] I. COX, J. REHG, ET S. HINGORANI, *A Bayesian Multiple-Hypothesis Approach to Edge Grouping and Contour Segmentation*, International Journal of Computer Vision, 11 (1993), pp. 5–24.
- [Crim-86] T. CRIMMINS, *Geometric filter for reducing speckle*, Optical Engineering, 25 (1986), pp. 651–654.
- [Curl-91] J. C. CURLANDER ET R. N. MCDONOUGH, *Synthetic Aperture Radar, Systems and Signal Processing*, A Volume in the Wiley Series in Remote Sensing, J.A. Kong, Series Editor, 1991.
- [Davi-90] C. DAVID ET S. ZUCKER, *Potentials, Valleys and Dynamic Global Coverings*, International Journal of Computer Vision, 5 (1990), pp. 219–238.
- [Deli-97] Y. DELIGNON, R. GARELLO, ET A. HILLION, *Statistical modelling of ocean SAR images*, IEEE Radar Sonar and Navigation (to appear), (1997).
- [Delv-91] L. M. DELVEST, R. T. MCQUILLAN, R. WILKINSON, J. B. E. SANDYS-RENTON, ET C. J. OLIVER, *A two-dimensional segmentation algorithm for SAR images*, Inverse Problems, 7 (1991), pp. 203–220.
- [Demp-68] A. P. DEMPSTER, *A generalization of Bayesian inference*, Journal of the Royal Statistical Society, 30 (1968).

- [Deno-95] T. DENOEU, *A k-nearest neighbor classification rule based on dempster-shafer theory*, IEEE Transactions on Systems, Man and Cybernetics, 25 (1995), pp. 804–813.
- [Deri-87] R. DERICHE, *Using Canny's criteria to derive a recursively implemented optimal edge detector*, International Journal of Remote Sensing, 2 (1987), pp. 167–187.
- [Deri-90] H. DERIN, P. A. KELLY, G. VEZINA, ET S. G. LABITT, *Modeling and segmentation of speckled images using complex data*, IEEE Transactions on Geoscience and Remote Sensing, 28 (1990), pp. 76–87.
- [Derin-87] H. DERIN ET H. ELLIOTT, *Modeling and segmentation of noisy and textured images using Gibbs Random Fields*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-9 (1987), pp. 39–55.
- [Desa-90] J. DESACHY, *ICARE : an expert system for automatic mapping from satellite imagery*, in Mapping and spatial modelling for navigation, L. F. Pau Springer Verlag Berlin Heidelberg, ed., vol. F65 of NATO-ASI, 1990.
- [Desc-93] X. DESCOMBES, *Champs Markoviens en analyse d'images*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (ENST 93 E 026), 1993.
- [Desc-95] X. DESCOMBES, J. F. MANGIN, E. PECHERSKY, ET M. SIGELLE, *Fine structures preserving Markov model for image processing*, The 9th Scandinavian Conference on Image Analysis (Uppsala, Sweden), 2 (1995), pp. 349–356.
- [Deut-72] E. S. DEUTSCH, *Thinning algorithms on rectangular, hexagonal, and triangular arrays*, CACM, 15 (1972), pp. 827–837.
- [Dewa-90] P. DEWAELE ET J. MARCHAND, *Comparison of some speckle reduction techniques for SAR images*, IGARSS'90, (1990), pp. 2417–2422.
- [Dobs-96] M. C. DOBSON, L. E. PIERCE, ET F. T. ULABY, *Knowledge-based land-cover classification using ERS-1/JERS-1 SAR composites*, IEEE Transactions on Geoscience and Remote Sensing, 34 (1996), pp. 83–99.
- [Dubo-82] D. DUBOIS, *On several representations of an uncertain body of evidence*, in Fuzzy information and decision process, M. M. Gupta et E. Sanchez, eds., North Holland, Ansterdam, The Netherlands, 1982, pp. 167–181.
- [Dubo-88] D. DUBOIS ET H. PRADE, *Representation and combination of uncertainty with belief functions and possibility measures*, Comput. Intell., 4 (1988), pp. 244–264.
- [Dubo-94] ———, *La fusion d'informations imprécises*, Traitement du Signal, 11 (1994), pp. 447–458.

- [Duda-72] R. D. DUDA ET P. E. HART, *Use of the hough transformation to detect lines and curves in pictures*, Comm. ACM, 15 (1972), pp. 11–15.
- [Duin] R. VAN DUIN ET G. DE KASTE, *The pocket guide to the Zuyder Zee project*, Casparie Almere bv.
- [ElAs-96] S. E. ASSAD, *Problématiques en imagerie radar. Reconstruction, Traitements (habilitation à diriger des recherches)*, rapp. tech., Université de Nantes, 1996.
- [Eshe-86] M. A. ESHERA ET K.-S. FU, *An image understanding system using attributed symbolic representation and inexact graph matching*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8 (1986), pp. 604–618.
- [Falc-96] T. FALCO, F. FRANCIS, S. LOVEJOY, D. SCHERTZER, B. KERMAN, ET M. DRINKWATER, *Universal multifractal scaling of synthetic aperture radar images of sea-ice*, IEEE Transactions on Geoscience and Remote Sensing, 34 (1996), pp. 906–913.
- [Fan-89] T.-J. FAN, G. MEDIONI, ET R. NEVATIA, *Recognizing 3-D objects using surface description*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-11 (1989), pp. 1140–1157.
- [Faug-81] O. FAUGERAS ET K. PRICE, *Semantic description of aerial images using stochastic labeling*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 3 (1981), pp. 633–642.
- [Finc-97] A. M. FINCH, R. C. WILSON, ET E. R. HANCOCK, *Matching Delaunay graphs*, Pattern Recognition, 30 (1997), pp. 123–140.
- [Fisc-81] M. A. FISCHLER, J. TENENBAUM, ET H. WOLF, *Detection of roads and linear structures in low resolution aerial imagery using a multisource knowledge integration technique*, Computer Graphics and Image Processing, 15 (1981), pp. 201–223.
- [Fjor-95] R. FJORTOFT, P. MARTON, A. LOPES, ET E. CUBERO-CASTAN, *Edge detection in radar images using recursive filters*, ACCV'95 Second Asian Conference on Computer Vision, (1995).
- [Fjor-97] ———, *Multi-edge detection in SAR images*, ICASSP'97, (1997).
- [Fjor-98] R. FJORTOFT, A. LOPES, P. MARTON, ET E. CUBERO-CASTAN, *An optimum multi-edge detector for SAR image segmentation*, IEEE Transactions on Geoscience and Remote Sensing (to appear), (1998).
- [Flas-97] B. FLASQUE, *Restauration d'images radar à ouverture synthétique multi-temporelles avec prise en compte des discontinuités*, rapp. tech., DEA Automatique et traitement du signal, 1997.

- [Fran-87] R. T. FRANKOT ET R. CHELLAPPA, *Lognormal random-field models and their applications to radar image synthesis*, IEEE Transactions on Geoscience and Remote Sensing, 25 (1987), pp. 195–207.
- [Fros-82] V. S. FROST, J. A. STILES, K. S. SHANMUGAN, ET J. C. HOLTZMAN, *A model for radar images and its application to adaptive digital filtering of multiplicative noise*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-4 (1982), pp. 157–166.
- [GEOS-95] C. GOUINAUD ET I. PONS, *Etude sur les paramètres angle d'incidence et heure locale d'acquisition d'un futur SAR*. Contrat CNES num : 95/0128, Juin 1995.
- [Garn-88] P. GARNESON, G. GIRAUDON, ET P. MONTESINOS, *Detecting buildings and roads in aerial images by a multi expert system*, Rapport de recherche INRIA, (1988).
- [Garn-89] ———, *Messie : un système multi-spécialistes en vision, application à l'interprétation en imagerie aérienne*, RFIA-AFCET'89 (Paris), (1989), pp. 817–832.
- [Geig-91] D. GEIGER ET F. GIROSI, *Parallel and deterministic algorithms from MRF's : Surface reconstruction*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 13 (1991), pp. 401–412.
- [Gema-84] S. GEMAN ET D. GEMAN, *Stochastic Relaxation, Gibbs Distribution, and the Bayesian Restoration of Images*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-6 (1984), pp. 721–741.
- [Gema-85] S. GEMAN ET D. E. MCCLURE, *Bayesian image analysis : an application to single photon emission tomography*, Proc. Statist. Comput. sect. (Amer. Statist. Assoc. Washington DC), (1985), pp. 12–18.
- [Gema-92] D. GEMAN ET G. REYNOLDS, *Constrained restoration and the recovery of discontinuities*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-14 (1992), pp. 367–383.
- [Gema-96] D. GEMAN ET B. JEDYNAK, *An active testing model for tracking roads in satellite images*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-18 (1996), pp. 1–14.
- [Gera-95] T. GÉRAUD, J. F. MANGIN, I. BLOCH, ET H. MAÎTRE, *Segmenting internal structures in 3D MR images of the brain by Markovian relaxation on a watershed based adjacency graph*, IEEE ICIP (Austin), III (1995), pp. 548–552.
- [Germ-97] O. GERMAIN ET P. RÉFRÉGIER, *Optimal snake-based segmentation of a random luminance target on a spatially disjoint background*, Optic Letters (to appear), (1997).

- [Giess-84] S. C. GIESS, *Edge detection in SAR imagery using gradient operators*, Royal Signals and Radar Establishment (RSRE Memorandum 3743), (1986).
- [Gold-88] R. M. GOLDSTEIN, H. A. ZEBKER, ET C. L. WERNER, *Satellite radar interferometry : two-dimensional phase unwrapping*, *Radio Science*, 23 (1988), pp. 713–720.
- [Good-75] J. GOODMAN, *Statistical properties of laser speckle patterns*, in *Laser Speckle and Related Phenomena*, vol. 9, J.C Dainty (Springer Verlag, Heidelberg, 1975), 1975, pp. 9–75.
- [Good-76] J. GOODMAN, *Some fundamental properties of speckle*, *Journal Optical Society of America*, 66 (1976), pp. 1145–1150.
- [Goui-91] C. GOUINAUD, *Le monde selon SAR : simulations et stéréovision sur images SAR*, rapp. tech., DESS de télédétection (Paris VII), 1991.
- [Goui-96] C. GOUINAUD, F. TUPIN, ET H. MAÎTRE, *Potential and use of radar images for characterization and detection of urban areas*, *IGARSS'96 (Nebraska)*, 1 (1996), pp. 474–476.
- [Goui-96b] C. GOUINAUD, *Traitement d'images satellitaires pour la détection d'agglomérations*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (96 E035), 1996.
- [Graf-89] C. GRAFFIGNE ET I. HERLIN, *Modélisation de réseaux pour l'imagerie satellite SPOT*, AFCET, 7th congrès de Reconnaissance des Formes et Intelligence Artificielle (Paris), (1989), pp. 833–842.
- [Graf-93] C. GRAFFIGNE ET C. LABOURDETTE, *Some segmentation algorithms and their parallel implementation*, Proc. ISI, Florence, (1993).
- [Graf-95] C. GRAFFIGNE, F. HEITZ, P. PEREZ, F. PRETEUX, M. SIGELLE, ET J. ZÉRUBIA, *Hierarchical Markov random field models applied to image analysis : a review*, SPIE Conference on Neural, Morphological, and Stochastic Methods in Image and Signal Processing (San Diego), (1995).
- [Gree-93] I. J. GREEN, F. G. SAWYER, ET S. B. DUNSTER, *SAR image feature extraction system - A pre-operational application of ERS-1 SAR*, Int. Symp. Operationalization of Remote Sensing (Enschede, The Netherlands), (1993), pp. 23–32.
- [Guer-93] P. GUERIN, *Recalage de données vecteur sur une image aérienne en vue d'une extraction automatique du réseau routier*, rapp. tech., ENST-IGN, 1993.
- [Habi-72] A. HABIBI, *Two-dimensional bayesian estimate of images*, *Proceedings of the IEEE*, 60 (1972), pp. 878–883.

- [Hans-88] A. HANSON, E. RISEMAN, ET T. WILLIAMS, *Sensor and information fusion from knowledge based constraints*, SPIE Sensor Fusion, 931 (1988), pp. 186–196.
- [Hara-73] R. M. HARALICK, K. SHANMUGAM, ET I. DINSTEIN, *Textural features for image classification*, IEEE Transactions on Systems, Man, and Cybernetics, SMC-3 (1973), pp. 610–621.
- [Hard-96] J. P. HARDANGE, P. LACOMME, ET J. C. MARCHAIS, *Radars aéroportés et spatiaux*, MASSON (Collection Scientifique et Technique Thomson-CSF), 1996.
- [Haye-83] B. HAYES-ROTH, *The blackboard architecture : A general framework for problem solving*, rapp. tech., Computer Science Department, Stanford University, 1983.
- [Hell-96] O. HELLWICH, H. MAYER, ET G. WINKLER, *Detection of lines in synthetic aperture radar (SAR) scenes*, ISPRS, Int. Archives of Photogrammetry and Remote Sensing, (Vienna), 31 (1996), pp. 312–320.
- [Hend-88] A. HENDRY, S. QUEGAN, ET J. WOOD, *The visibility of linear features in SAR images*, IGARSS'88 (Edinburgh, Scotland), (1988), pp. 1517–1520.
- [Hend-88b] A. HENDRY, J. SKINGLEY, ET A. J. RYE, *Automated linear feature detection and its application to curve location in Synthetic Aperture Radar imagery*, IGARSS'88 (Edinburgh, Scotland), (1988), pp. 1521–1524.
- [Hera-92] L. HÉRAULT ET R. HORAUD, *Figure-ground discrimination by mean field annealing*, Proc. ECCV 92 (Santa Margherita), (1992), pp. 58–66.
- [Hill-88] A. HILLION ET J.-M. BOUCHER, *A new non linear filtering algorithm with application to radar images*, Proc. RADAR-88, (1988), pp. 177–181.
- [Hill-91] A. HILLION ET J.-M. BOUCHER, *Filtrage des images radar (SAR)*, Statistique et analyse des données, 16 (1992), pp. 35–57.
- [Hoek-91] D. H. HOEKMAN, *Speckle ensemble statistics of logarithmically scaled data*, IEEE Transactions on Geoscience And Remote Sensing, TGARS-29 (1991), pp. 180–182.
- [Hora-89] R. HORAUD ET T. SKORDAS, *Stereo correspondence through feature grouping and maximal cliques*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-11 (1989), pp. 1168–1180.
- [Horn-75] B. HORN, *Obtaining Shape from Shading Information*, McGraw-Hill Book Company, 1975.
- [Houz-93] S. HOUZELLE, *Extraction automatique d'objets cartographiques par fusion d'informations extraites d'images satellites*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (93 E 001), 1993.

- [Houz-94] S. HOUZELLE ET G. GIRAUDON, *Contribution to multisensor fusion formalization*, Robotics and Autonomous Systems, 13 (1995), pp. 69–85.
- [Huec-71] M. H. HUECKEL, *An operator which locates edges in digitized pictures*, Journal of the Association for Computing Machinery, 18 (1971), pp. 191–203.
- [Jacq-97] F. JACQUIS, *Techniques de corrélation pour la radargrammétrie, filtrage et détection de structures, application à des images satellites ROS ERS-1*, Thèse de doctorat, Université Joseph Fourier, Grenoble I, 1997.
- [Jake-80] E. JAKEMAN, *On the statistics of K-distributed noise*, J. Phys. A : Math. Gen., 13 (1980), pp. 31–48.
- [Jake-87] E. JAKEMAN ET J. A. TOUGH, *Generalized K distribution : a statistical model for weak scattering*, J. Opt. Soc. Am., 4 (1987), pp. 1764–1772.
- [Jake-88] ———, *Non gaussian models for the statistics of scattered waves*, Advances in Physics, 37 (1988), pp. 471–529.
- [Jane-97] F. JANEZ, *Rappels sur la théorie de l'évidence*, rapp. tech., Offices Nationales d'Etudes et de Recherches Aérospatiales, 1997.
- [Jao-84] J. K. JAO, *Amplitude distribution of composite terrain radar clutter and the K-distribution*, IEEE Transactions on Antennas and Propagation, AP-32 (1984), pp. 1049–1062.
- [Jedy-91] B. JÉDYNAK, D. GEMAN, ET A. GAGALOWICZ, *Détection de réseaux routiers à partir des images du satellite SPOT*, 9th RFIA-AFCET (Lyon-Villeurbanne), (1991), pp. 489–494.
- [Jedy-95] B. JÉDYNAK, *Modèles stochastiques et méthodes déterministes pour extraire les routes des images de la terre vues du ciel*, Thèse de doctorat, Université Paris SUD, 1995.
- [Jung-87] C. JUNG, *Etude et correction de l'influence du relief sur la radiométrie d'une image de radar à ouverture synthétique par simulation de la réponse radar*, Thèse de doctorat, Université Paris VII, 1987.
- [Kash-83] R. L. KASHYAP ET R. CHELLAPPA, *Estimation and choice of neighbors in spatial-interaction models of images*, IEEE Transactions in Information Theory, 29 (1983), pp. 60–72.
- [Kass-88] M. KASS, A. WITKIN, ET D. TERZOPOULOS, *Snakes : Active contours models*, International Journal of Computer Vision, 1 (1988), pp. 321–331.
- [Kato-94] Z. KATO, *Modélisations markoviennes multi-résolutions en vision par ordinateur. Application à la segmentation d'images SPOT*, Thèse de doctorat, Université de Nice-Sophia Antipolis, 1994.

- [Kell-88] P. A. KELLY, H. DERIN, ET K. D. HARTT, *Adaptive segmentation of speckled images using a hierarchical random field model*, IEEE Transactions on Acoustics, Speech and Signal Processing, ASSP-36 (1988), pp. 1628–1641.
- [Kend-69] M. G. KENDALL ET A. STUART, *The Advanced Theory of Statistics*, vol. 1, Griffin, 3 ed., 1969.
- [Kim-93] I. Y. KIM ET H. YANG, *Efficient image labeling based on Markov random field and error backpropagation network*, Pattern Recognition, 26 (1993), pp. 1695–1707.
- [Kim-95] H. KIM ET P. H. SWAIN, *Evidential reasoning approach to multisource data classification in remote sensing*, IEEE Transactions on Systems, Man and Cybernetics, 25 (1995), pp. 1257–1265.
- [Kuan-85] D. T. KUAN, A. A. SAWCHUK, T. C. STRAND, ET P. CHAVEL, *Adaptive noise smoothing filter for images with signal dependant noise*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-7 (1985), pp. 165–177.
- [Kuan-87] KUAN, SAWCHUK, STRAND, ET CHAVEL, *Adaptive restoration of images with speckle*, IEEE Transactions on Acoustics, Speech, and Signal Processing, ASSP-35 (1987), pp. 373–383.
- [Kwok-89] R. KWOK, *Segmentation of SAR images*, IGARSS'89 (Vancouver), (1989), pp. 1228–1230.
- [LAS-95] E. S. AGENCY, *Land and Sea ERS-1 Applications*. Workshop ESA ERS Applications (Londres), esa br-109, 1995.
- [Laar-87] P. J. LAARHOVEN ET E. H. AARTS, *Simulated annealing : theory and applications*, Reidel Oub. (Dordrecht, Holland), (1987).
- [Labr-95] D. LABROUSSE, S. DUPONT, ET M. BERTHOD, *Synthetic aperture radar interferometry : a Markovian approach for phase unwrapping*, SPIE Conference, Orlando, (1995).
- [Lacr-88] V. LACROIX, *A three module strategy for edge detection*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-10 (1988), pp. 803–810.
- [Laur-87] H. LAUR, T. L. TOAN, ET A. LOPES, *Textural segmentation of SAR images using first order statistical parameters*, in Proceedings of IGARSS'87 Symposium, vol. 2, Mai 1987, pp. 1463–1468.
- [Laur-89] H. LAUR, *Analyse d'images radar en télédétection, discriminateurs radiométriques et texturaux*, Thèse de doctorat, Université Paul Sabatier de Toulouse, 1989.

- [LeHe-96] S. L. HÉGARAT-MASCLE, *Classification non supervisée d'images SAR polarimétriques*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (ENST 96 E 024), 1996.
- [LeHe-97] S. LE HÉGARAT-MASCLE, I. BLOCH, ET D. VIDAL-MADJAR, *Application of Dempster-Shafer evidence theory to unsupervised classification in multi-source remote sensing*, IEEE Transactions on Geoscience and Remote Sensing (to appear), 35 (1997), pp. 1018–1032.
- [LeTo-97] T. L. TOAN, F. RIBBES, L.-F. WANG, N. FLOURY, K.-H. DING, J. A. KONG, M. FUJITA, ET T. KUROSU, *Rice crop mapping and monitoring using ERS-1 data based on experiment and modeling results*, IEEE Transactions on Geoscience and Remote Sensing, 35 (1997), pp. 41–55.
- [Lebe-86] F. W. LEBERL, G. DOMIK, J. RAGAM, ET M. KOBRICK, *Radar stereomapping techniques and application to SIR-B images of Mt. Shasta*, IEEE Transactions on Geoscience and Remote Sensing, 24 (1986), pp. 473–481.
- [Lebe-90] F. W. LEBERL, *Radargrammetric Image Processing*, Artech House, 1990.
- [Lebed-95] D. LEBEDEFF, *Etude de la quantification vectorielle des données brutes d'un radar à synthèse d'ouverture*, Thèse de doctorat, Université de Nice-Sophia Antipolis, 1995.
- [Lee-80] J.-S. LEE, *Digital image enhancement and noise filtering by use of local statistics*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-2 (1980), pp. 165–168.
- [Lee-81a] J.-S. LEE, *Speckle analysis and smoothing of synthetic aperture radar images*, Computer Graphics and Image Processing, 17 (1981), pp. 24–32.
- [Lee-81b] ———, *Refined filtering of image noise using local statistics*, Computer Graphics and Image Processing, 15 (1981), pp. 380–389.
- [Lee-87] T. L. LEE, J. A. RICHARDS, ET P. H. SWAIN, *Probabilistic and evidential approaches for multisource data analysis*, IEEE Transactions on Geoscience and Remote Sensing, 25 (1987), pp. 183–293.
- [Lewi-83] D. J. LEWINSKI, *Nonstationary probabilistic target and clutter scattering models*, IEEE Transactions on Antennas and Propagation, 31 (1983), pp. 490–498.
- [Li-83] F.-K. LI, C. CROFT, ET D. N. HELD, *Comparison of several techniques to obtain multiple-look SAR imagery*, IEEE Transactions on Geoscience and Remote Sensing, 21 (1983), pp. 370–375.
- [Lomb-94] P. LOMBARDO ET C. OLIVER, *Simultaneous segmentation of texture properties of K-distributed SAR images*, Satellite Remote Sensing I, EUROPTO (Rome), 2316 (1994), pp. 104–114.

- [Lope-90] A. LOPES, R. TOUZI, ET E. NEZRY, *Adaptative speckle filters and scene heterogeneity*, IEEE Transactions on Geoscience and Remote Sensing, 28 (1990), pp. 992–1000.
- [Lope-90b] A. LOPES, *Téledétection active par radars*, Cours du GDTA (Groupement pour le Développement de la Téledétection Aérospatiale), (1990).
- [Lope-93b] A. LOPES, E. NEZRY, R. TOUZI, ET H. LAUR, *Structure detection, and statistical adaptive filtering in SAR images*, Int. J. Remote Sensing, 14 (1993), pp. 1735–1758.
- [Lope-97] A. LOPES ET F. SERY, *Optimal speckle reduction for the product model in multilook polarimetric data and the complex Wishart distribution*, IEEE Transactions on Geoscience and Remote Sensing, 35 (1997), pp. 632–647.
- [Lowe-89] D. G. LOWE, *Organization of smooth image curves at multiple scales*, Second International Conference on Computer Vision (Florida, USA), (1989), pp. 558–567.
- [Lowr-91] J. D. LOWRANCE, T. M. STRAT, L. P. WESLEY, T. D. GARVEY, E. H. RUSPINI, ET D. E. WILKINS, *The theory, implementation and practice of evidential reasoning*, rapp. tech., SRI International, 1991.
- [Main-94] P. MAINGUENAUD ET R. JEANSOULIN, *Multi-source SAR image texture classification using an artificial neural network model*, Satellite Remote Sensing I, EUROPTO (Rome, Italy), 2315 (1994), pp. 12–21.
- [Mait-96] H. M. ET AL., *Cartographie automatique urbaine sur les simulations SPOT-5 -Rapport de Marché CNES 95-0316*, rapp. tech., Ecole Nationale Supérieure des Télécommunications, Juil. 1996.
- [Mang-92] F. MANGIN, M. BERTHOD, ET J. ZERUBIA, *A cooperative network for contour grouping*, The 11th International Conference on Pattern Recognition (ICPR), The Hague, The Netherlands, (1992).
- [Mang-94] F. MANGIN, *Amélioration de la détection de Contours en Imagerie Artificielle par un Modèle Coopératif Multi-Résolution*, Thèse de doctorat, Université de Nice - Sophia Antipolis, 1994.
- [Mang-95a] J. F. MANGIN, *Mise en correspondance d'images médicales 3D multi-modalités multi-individus pour la corrélation anatomo-fonctionnelle cérébrale*, Thèse de doctorat, Ecole Nationale des Télécommunications (ENST 95 E 010), 1995.
- [Mang-95b] J. F. MANGIN, F. TUPIN, V. FROUIN, I. BLOCH, R. ROUGETET, J. REGIS, ET J. LOPEZ-KRAHE, *Deformable topological models for segmentation of 3D medical images*, XIVth. International Conference on Information Processing in Medical Imaging (Berder, France), (1995), pp. 153–164.

- [Marr-89] J. L. MARROQUIN, *A Markovian Random Field of piecewise straight lines*, Biological Cybernetics, 61 (1989), pp. 457–465.
- [Mart-96] P. MARTINEZ, D. SCHERTZER, ET K. PHAM, *Texture analysis by universal multifractal features in a polarimetric SAR images*, IGARSS'96 (Nebraska), (1996), pp. 37–39.
- [Maru-95] A. MARUANI, M. SIGELLE, ET E. PECHERSKY, *On Gibbs Fields in image processing*, Markov Processes and Related Fields, 1 (1995), pp. 419–442.
- [Marz-96] A. MARZOUKI, *Segmentation statistique d'images radar*, Thèse de doctorat, Université des Sciences et Technologies de Lille, 1996.
- [Masso-93] D. MASSONNET ET T. RABAUTE, *Radar interferometry : limits and potential*, IEEE Transactions on Geoscience and Remote Sensing, 31 (1993), pp. 445–464.
- [Math-97] P. MATHIEU, L. DIRAT, X. DUPUIS, ET M. BARLAUD, *Speckle reduction with edge-preserving*, ICASSP'97 (Munich), (1997).
- [Mats-86] T. MATSUYAMA, *Knowledge-based aerial image understanding systems and expert systems for image processing*, International Geoscience and Remote Sensing Symposium (Zurich), (1986), pp. 1026–1038.
- [McKe-85] D. M. MCKEOWN, W. A. HARVEY, ET J. MCDERMOTT, *Rule-based interpretation of aerial imagery*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-7 (1985), pp. 570–585.
- [McKe-89] D. M. MCKEOWN, W. HARVEY, ET L. E. WIXSON, *Automatic knowledge acquisition for aerial image interpretation*, Computer Vision, Graphics and Image Processing, 46 (1989), pp. 37–81.
- [McKeo-88] D. M. MCKEOWN ET J. L. DENLINGER, *Cooperative methods for road tracking in aerial imagery*, Proceedings of IEEE Computer Vision and Pattern Recognition (Ann Arbor, USA), (1988), pp. 662–672.
- [McLa-96] R. A. MCLAUGHLIN, *Randomized Hough transform : Better ellipse detection*, IEEE Tencon Digital Signal Processing Applications, (1996), pp. 409–414.
- [Merl-93] N. MERLET ET J. ZERUBIA, *A curvature-dependent energy function for detecting lines in satellite images*, Proc. 8th SCIA (Tromso, Norway), (1993).
- [Merl-96] ———, *New prospects in line detection by dynamic programming*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 18 (1996), pp. 426–431.
- [Mey-92] Y. MEYER, *Les Ondelettes, Algorithmes et Applications*, Armand Colin, 1992.

- [Moct-95] M. MOCTEZUMA, *Analyse de séquences d'images satellitaires et détermination des modifications géographiques des paysages*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (ENST 95 E 011), Mars 1995.
- [Mois-96] H. MOISSINAC-MASSENAT, *Utilisation conjointe d'informations symboliques et de mesures numériques dans la prise de décision en traitement d'images*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (ENST 96 E 007), 1996.
- [Nast-94] C. NASTAR, *Modèles Physiques Déformables et Modes Vibratoires pour l'Analyse du Mouvement non-rigide dans les Images Multidimensionnelles*, Thèse de doctorat, Ecole Nationale des Ponts et Chaussées, 1994.
- [Neue-95] W. NEUENSCHWANDER, P. FUA, G.SZÉKELY, ET O. KÜBLER, *Ziplock snakes*, International Journal of Control Vision (submitted), (1995).
- [Neva-80] R. NEVATIA ET R. BABU, *Linear feature extraction and description*, Computer Graphics and Image Processing, 13 (1980), pp. 257–269.
- [Nezr-92] E. NEZRY, *Restauration de la réflectivité radar, application à l'utilisation conjointe des images des radars à synthèse d'ouverture et optiques en télé-detection*, Thèse de doctorat, Université Paul Sabatier de Toulouse, 1992.
- [Nezr-96] E. NEZRY, A. LOPES, C. N. D. DUCROT-GAMBART, ET J.-S. LEE, *Supervised classification of K-distributed SAR images of natural targets and probability of error estimation*, IEEE Transactions on Geoscience and Remote Sensing, 34 (1996), pp. 1233–1242.
- [Nico-97] J. M. NICOLAS, M. SIGELLE, C. THUILLIER, ET F. TUPIN, *Images de radar à ouverture synthétique : transformée de Mellin et multirésolution*, GRETSI 97 (to appear), (1997).
- [Noce-96] L. NOCERA, *Reconstruction du relief en imagerie radar à ouverture de synthèse : stéréoscopie et ombrages*, Thèse de doctorat, Université de Paris 7 Jussieu, 1996.
- [Oblo-85] E. M. OBLow, *A hybrid uncertainty theory*, 5èmes Journées Internationales "Les systèmes experts et leurs applications", Avignon, France, (1985), pp. 1193–1201.
- [Ogor-96] B. OGOR, V. HAESE-COAT, ET J. RONSIN, *SAR image segmentation by mathematical morphology and texture analysis*, IGARSS'96, Nebraska, (1996), pp. 717–719.
- [Oliv-84] C. J. OLIVER, *A model for non-Rayleigh scattering statistics*, Optica Acta, 31 (1984), pp. 701–722.
- [Oliv-86] ———, *The interpretation and simulation of clutter textures in coherent images*, Inverse Problems, 2 (1986), pp. 481–518.

- [Oliv-94b] C. OLIVER, A. BLAKE, ET R. WHITE, *Optimum texture analysis of Synthetic Aperture Radar images*, SPIE International Conference "Algorithms for SAR Imagery", 2230 (1994), pp. 389–398.
- [Oliv-95] C. J. OLIVER, I. M. CONNELL, D. BLACKNELL, ET R. G. WHITE, *Optimum edge detection in SAR images*, Satellite Remote Sensing II EUROPTO (Paris), 2584 (1995), pp. 152–163.
- [Paqu-96] S. PAQUERAULT, H. MAÎTRE, ET J. NICOLAS, *Radarclinometry for ERS-1 data mapping*, IGARSS'96 (Lincoln, Nebraska, USA), 1 (1996), pp. 503–505.
- [Pare-89] P. PARENT ET S. W. ZUCKER, *Trace inference, curvature consistency, and curve detection*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-11 (1989), pp. 823–839.
- [Pere-93] P. PÉREZ, *Champs markoviens et analyse multirésolution de l'image : application à l'analyse du mouvement*, Thèse de doctorat, Université de Rennes I, 1993.
- [Piec-94] W. PIECZYNSKI, *Hidden markov fields and iterative conditional estimation*, Traitement du Signal, 11 (1994), pp. 141–153.
- [Pier-94] L. E. PIERCE, F. ULABY, K. SARABANDI, ET M. C. DOBSON, *Knowledge-based classification of polarimetric SAR images*, IEEE Transactions on Geoscience and Remote Sensing, 32 (1994), pp. 1081–1094.
- [Prat-90] C. PRATI ET F. ROCCA, *Limits to the resolution of elevation maps from stereo SAR images*, International Journal of Remote Sensing, 11 (1990), pp. 2215–2235.
- [Prep-88] F. P. PREPARATA ET M. I. SHAMOS, *Computational Geometry, an introduction*, Texts and monographs in Computer Science, Springer Verlag, 1988.
- [Queg-86] S. QUEGAN, A. HENDRY, ET J. SKINGLEY, *Analysis of synthetic aperture radar images over land*, Mathematics in Remote Sensing (Danbury), (1986), pp. 365–379.
- [Queg-94] S. QUEGAN, *An introduction to SAR theory, statistical properties of ERS-1 SAR data and scattering mechanisms*, Workshop New Directions in Remote Sensing, (1994), p. 1994.
- [Quel-91] H.-C. QUELLE, J.-M. BOUCHER, ET W. PIECZYNSKI, *Unsupervised bayesian classification of SAR images*, IGARSS'91 (Espoo, Finland), (1991), pp. 2177–2180.
- [Quel-93] H.-C. QUELLE, *Segmentation bayésienne non supervisée en imagerie radar*, Thèse de doctorat, Université de Rennes I, 1993.

- [Rama-86] H. RAMAPRIYAN, J. STRONG, Y. HUNG, ET C. MURRAY, *Automated matching of pairs of SIR-B images for elevation mapping*, IEEE Transactions on Geoscience and Remote Sensing, TGARS-4 (1986).
- [Rega-94] C. S. REGAZZONI, *Global probabilistic reinforcement of straight segments*, Time-Varying Image Processing and Moving Object Recognition, 3 (Firenze, Italy), (1994), pp. 95–102.
- [Rega-94b] C. S. REGAZZONI, F. ARDUINI, ET G. VERNAZZA, *A multilevel GMRF-based approach to image segmentation and restoration*, EUROPTO, Image and Signal Processing for Remote Sensing (Rome), 2315 (1994), pp. 43–67.
- [Rega-95] C. S. REGAZZONI, G. L. FORESTI, ET S. B. SERPICO, *An adaptive probabilistic model for straight edge-extraction within a multilevel MRF framework*, IGARSS'95 (Firenze, Italy), (1995), pp. 458–460.
- [Ribb-96] F. RIBBES ET T. L. TOAN, *Use of ERS-1 SAR data for ricefield mapping and rice crop parameters retrieval*, IGARSS'96 (Nebraska), (1996), pp. 1983–1985.
- [Rign-91a] E. RIGNOT, R. CHELLAPPA, ET R. KWOK, *Classification of multifrequency multilook synthetic aperture radar data*, conference IEEE, (1991), pp. 1801–1804.
- [Rign-91b] E. RIGNOT ET R. CHELLAPPA, *Segmentation of polarimetric synthetic aperture radar data*, IEEE Transactions on Signal Processing, (1991).
- [Roux-92] M. ROUX, J. LOPEZ-KRAHE, ET H. MAÎTRE, *Recalage image SPOT / carte routière*, XVIIe Congrès ISPRS, Washington, (1992), pp. 384–391.
- [Rusk-95] R. RUSKONÉ, S. AIRAULT, ET O. JAMET, *Road network extraction by local context interpretation*, EUROPTO-SPIE 95, 2579 (1995), pp. 126–136.
- [Saad-96] A. SAAD, *Filtrage et Segmentation d'Images Radar polarimétriques*, Thèse de doctorat, Université de Nantes, 1996.
- [Sama-90] R. SAMADANI ET J. F. VESECKY, *Finding curvilinear features in speckled images*, IEEE Transactions on Geoscience and Remote Sensing, 28 (1990), pp. 669–673.
- [Sapo-78] G. SAPORTA, *Théories et méthodes statistiques*, Princeton University Press, 1978.
- [Schi-95] A. H. SCHISTAD ET A. K. JAIN, *Texture analysis of SAR images: A comparative study*, IEEE Transactions on Geoscience and Remote Sensing (submitted), (1995).
- [Sery-97] F. SERY, *Filtrage du speckle dans les images RSO polarimétriques et classification non supervisée multi-sources*, Thèse de doctorat, Université Paul Sabatier (Toulouse III), 1997.

- [Shaf-76] G. SHAFER, *A mathematical theory of evidence*, Princeton University Press, 1976.
- [Shan-81] K. S. SHANMUGAN, V. NARAYANAN, V. S. FROST, J. A. STILES, ET J. C. HOLTZMAN, *Textural features for radar image analysis*, IEEE Transactions on Geoscience and Remote Sensing, 19 (1981), pp. 153–156.
- [Shen-96] Y. SHENG ET Z.-G. XIA, *A comprehensive evaluation of filters for radar speckle suppression*, IGARSS'96 (Nebraska), (1996), pp. 1559–1564.
- [Skin-87] J. SKINGLEY ET A. J. RYE, *The Hough transform applied to SAR images for thin line detection*, Pattern Recognition Letters, 6 (1987), pp. 61–67.
- [Smet-90] P. SMETS, *The combination of evidence in the transferable belief model*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 12 (1990), pp. 447–458.
- [Smet-95] ———, *The transferable belief model for uncertainty representation*, rapp. tech., IRIDIA, Université Libre de Bruxelles, 1995.
- [Smet-97] ———, *The alpha-junctions: the commutative combination operators applicable to belief functions*, rapp. tech., IRIDIA 97-1, Bruxelles, 1997.
- [Smit-96] P. C. SMITS, S. DELLEPIANE, ET S. B. SERPICO, *Markov random field based images segmentation with adaptive neighborhoods to the detection of fine structures in SAR data*, IGARSS'96, Nebraska, (1996), pp. 714–716.
- [Smit-97] P. C. SMITS ET S. G. DELLEPIANE, *Synthetic aperture radar image segmentation detail preserving markov random field approach*, IEEE Transactions on Geoscience and Remote Sensing, 35 (1997), pp. 844–857.
- [Soh-96] L.-K. SOH ET C. TSATSOUKIS, *Texture representation of SAR sea ice imagery using multi-displacement co-occurrence matrices*, IGARSS'96 (Nebraska), (1996), pp. 112–114.
- [Stof-95] E. R. STOFAN, D. L. EVANS, C. SCHMULLIUS, B. HOLT, J. J. PLAUT, J. VAN ZYL, S. D. WALL, ET J. WAY, *Overview of results of Spaceborne Imaging Radar-C, X-band Synthetic Aperture Radar (SIR-C/X-SAR)*, IEEE Transactions on Geoscience and Remote Sensing, 33 (1995), pp. 817–827.
- [Tene-77] J. M. TENENBAUM ET H. G. BARROW, *Experiments in interpretation-guided segmentation*, Artificial Intelligence, 8 (1977), pp. 241–274.
- [Touz-88a] R. TOUZI, *Analyse d'images radar en télédétection : améliorations radiométriques, filtrage du speckle et détection des contours*, Thèse de doctorat, Université Paul Sabatier de Toulouse, 1988.
- [Touz-88b] R. TOUZI, A. LOPES, ET P. BOUSQUET, *A statistical and geometrical edge detector for SAR images*, IEEE Transactions on Geoscience and Remote Sensing, 26 (1988), pp. 764 – 773.

- [Trei-96] P. M. TREITZ, O. R. FILHO, P. J. HOWARTH, ET E. D. SOULIS, *Textural processing of multi-polarization SAR for agricultural crop classification*, IGARSS'96, (1996), pp. 1986–1988.
- [Trou-96] E. TROUVÉ, *Imagerie interférentielle en radar à visée latérale*, Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications (ENST 96 E 014), 1996.
- [Tupi-95] F. TUPIN, C. GOUINAUD, H. MAÎTRE, ET J. NICOLAS, *Potential of ERS-1 images for characterization and detection of man-made structures: road network and urban areas*, Second ERS Application Workshop 95 (London), (1995), pp. 373–380.
- [Tupi-96] F. TUPIN, C. GOUINAUD, H. MAÎTRE, J.-P. CRETTEZ, ET J.-M. NICOLAS, *Détection de structures linéaires sur des images ROS*, *Traitement du Signal*, 13 (1997), pp. 635–650.
- [Tupi-96a] F. TUPIN, C. GOUINAUD, H. MAÎTRE, ET J.-P. CRETTEZ, *Détection du réseau routier sur des images radar ERS1*, RFIA AFCET 96 (Rennes), (1996), pp. 43–52.
- [Tupi-96b] F. TUPIN, H. MAÎTRE, J.-F. MANGIN, J.-M. NICOLAS, ET E. PECHERSKY, *Detection of linear features in SAR images: application to road network extraction*, *IEEE Transactions on Geoscience and Remote Sensing* (to appear, rapport interne ENST 96D006), (1997).
- [Tupi-96c] F. TUPIN, E. TROUVÉ, X. DESCOMBES, J.-M. NICOLAS, ET H. MAÎTRE, *Improving IFSAR phase unwrapping by early detection of non-interferometric features*, *European Symposium on Satellite Remote Sensing III* (Taormina, Italy), (1996).
- [Tupi-97] F. TUPIN, M. SIGELLE, A. CHKEIF, ET J.-P. VERAN, *Restoration of SAR images using recovery of discontinuities and non-linear optimization*, *EMMCVPR'97* (to appear), (1997).
- [Ulab-80] F. T. ULABY, *Vegetation clutter model*, *IEEE Transactions on Antennas and Propagation*, 28 (1980), pp. 538–545.
- [Ulab-82] F. T. ULABY, R. K. MOORE, ET A. K. FUNG, *Microwave remote sensing, volume II*, Artech House, 1982.
- [Ulab-86] F. T. ULABY, F. KOUYATE, B. BRISCO, ET T. L. WILLIAMS, *Textural information in SAR images*, *IEEE Transactions on Geoscience and Remote Sensing*, 24 (1986), pp. 235–245.
- [Urag-94] S. URAGO, M. BERTHOD, ET J. ZERUBIA, *An extension of an algorithm proposed by j. l. Marroquin for the restoration of incomplete contour images. application to real images*, *Traitement du Signal*, 11 (1994), pp. 179–194.

- [Urag-96] S. URAGO, *Groupements de contours en utilisant des modélisations markoviennes*, Thèse de doctorat, Université de Sophia-Antipolis, 1996.
- [Vand-76] G. J. VANDERBRUG, *Line detection in satellite imagery*, IEEE Transactions on Geoscience Electronics, GE-14 (1976), pp. 37–44.
- [Vand-77] G. J. VANDERBRUG, *Experiments in iterative enhancement of linear features*, Computer Graphics and Image Processing, 6 (1977), pp. 25–42.
- [Way-91] J. WAY ET E. A. SMITH, *The evolution of Synthetic Aperture Radar Systems and their progression to the EOS SAR*, IEEE Transactions on Geoscience and Remote Sensing, 29 (1991), pp. 962–985.
- [Welc-88] R. WELCH ET M. EHLERS, *Cartographic feature extraction with integrated SIR-B and Landsat TM images*, International Journal of Remote Sensing, 9 (1988), pp. 873–889.
- [Wesz-76] J. WESZKA, C. R. DYER, ET A. ROSENFELD, *A comparative study of texture measures for terrain classification*, IEEE Transactions on Systems, Man and Cybernetics, SMC-6 (1976), pp. 269–285.
- [Whit-91] R. G. WHITE, *Change detection in SAR imagery*, International Journal of Remote Sensing, 12 (1991), pp. 339–360.
- [Widl-86a] R. L. WIDLEY, *Radarclinometry*, Earth, Moon and Planets, 36 (1986), pp. 217–247.
- [Wood-85] J. W. WOOD, *Line finding algorithms for SAR*, Royal Signals and Radar Establishment (Memorandum 3 841), (1985).
- [Wu-92] Y. WU ET H. MAÎTRE, *Smoothing speckled synthetic aperture radar images by using maximum homogeneous region filters*, Optical Engineering, 31 (1992), pp. 1785–1792.
- [Yage-83] R. R. YAGER, *Hedging in the combination of evidence*, Journal of Information and Optimization Science, 4 (1983), pp. 73–81.
- [Yage-85] ———, *On the relationship of methods of aggregation evidence in expert systems*, Cybernetics and Systems, 16 (1985), pp. 1–21.
- [Yan-86] P. F. YAN ET C. H. CHEN, *An algorithm for filtering multiplicative noise in wide range*, Traitement du signal, 3 (1986), pp. 91–96.
- [Zade-65] L. A. ZADEH, *Fussy sets*, Information and Control, 8 (1965), pp. 338–353.
- [Zade-68] ———, *Probability measures of fuzzy events*, Journal of Mathematical Analysis and Applications, 23 (1968), pp. 421–427.
- [Zade-78] ———, *Fuzzy sets as a basis for a theory of possibility*, Fuzzy Sets and Systems, 1 (1978), pp. 3–28.

- [Zahz-92] E. ZAHZAH, *Contribution à la représentation des connaissances et à leur utilisation pour l'interprétation, automatique des images satellites*, Thèse de doctorat, Université Paul Sabatier (Toulouse), 1992.