



HAL
open science

Détection des galaxies à faible brillance de surface et segmentation hyperspectrale dans le cadre de l'observatoire virtuel

Matthieu Petremand

► **To cite this version:**

Matthieu Petremand. Détection des galaxies à faible brillance de surface et segmentation hyperspectrale dans le cadre de l'observatoire virtuel. Traitement du signal et de l'image [eess.SP]. Université Louis Pasteur - Strasbourg I, 2006. Français. NNT: . tel-00152065

HAL Id: tel-00152065

<https://theses.hal.science/tel-00152065>

Submitted on 6 Jun 2007

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

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



N° d'ordre :

THÈSE

présentée pour obtenir le grade de
Docteur de l'Université Louis Pasteur - Strasbourg I

École doctorale : Sciences de la Terre, de l'Univers et de l'Environnement de Strasbourg
Discipline : Informatique
Spécialité : Traitement d'images et vision par ordinateur

Détection des galaxies à faible brillance de surface, segmentation hyperspectrale dans le cadre de l'observatoire virtuel

Matthieu PETREMAND

Membres du jury :

Rapporteur interne :	C. BOILY	Maître de conférences, HDR	ULP, Strasbourg
Rapporteur externe :	E. SLÉZAK	Astronome adjoint, HDR	OCA, Nice
Rapporteur externe :	K. CHEHDI	Professeur	ENSSAT, Lannion
Directeur de thèse :	C. COLLET	Professeur	ULP, Strasbourg
Directrice de thèse :	F. GENOVA	Direct. de Rech.	CDS, Strasbourg
Examineur :	M. LOUYS	Maître de conférences	ULP, Strasbourg
Invité :	F. BONNAREL	Ingénieur de recherche	CDS, Strasbourg

Travail effectué au sein du Laboratoire des Sciences
de l'Image, de l'Informatique et de la Télédétection, UMR - 7005 CNRS - ULP
et de l'observatoire astronomique de Strasbourg, UMR - 7550 CNRS

Remerciements

Je remercie Messieurs Kacem Chehdi, Christian Boily et Eric Slézak pour l'intérêt qu'ils ont portés à mes travaux en acceptant la tâche de rapporteurs. Je remercie également Monsieur François Bonnarel et Madame Mireille Louys pour avoir accepté de participer au jury.

Je remercie mon directeur de thèse Monsieur Christophe Collet pour la confiance, le soutien et la disponibilité qu'il m'a accordé ainsi que pour la justesse et la pertinence des conseils qu'il m'a prodigué durant ces trois années de thèse. Je lui suis reconnaissant de m'avoir fait partager son enthousiasme et son goût pour la recherche.

Ce travail a été réalisé au LSIIT (Laboratoire des Sciences de l'Image, de l'Informatique et de la Télédétection), dans l'équipe MIV (Modèles, Images et Vision) en collaboration avec le CDS (Centre de Données astronomiques de Strasbourg) dans le cadre de l'ACI MDA (Masses de Données en Astronomie). J'exprime ma gratitude à Madame Françoise Genova, directrice du CDS, et à Monsieur Fabrice Heitz, directeur du LSIIT, pour leur accueil dans leur laboratoire respectif.

Je tiens également à remercier François Bonnarel et Mireille Louys pour leur aide et leurs conseils prodigués tout au long de ma thèse ainsi que pour avoir supporté mes incessants allers-retours dans leur bureau. Je les remercie également, ainsi que Bernd Vollmer et Eric Slézak pour m'avoir patiemment et toujours brillamment enseignés les concepts astronomiques nécessaires aux travaux menés dans cette thèse.

Merci à tous les membres des équipes MIV et CDS, pour leur gentillesse et leur soutien. Plus particulièrement, je remercie Farid, Matthieu, Alex, André, Christian, Fabien, Jean Julien, et Thomas pour toutes les discussions scientifiques (ou pas) qui m'ont permises d'avancer dans ma thèse.

Je ne dérogerai pas à la règle consistant à remercier mes proches car ce sont également eux qui m'ont permis d'avancer dans mes travaux. Je remercie ainsi ma famille pour son soutien et ses encouragements quasi-quotidien. Merci également à Felagund (*aka Jérôme*) qui m'a accompagné pendant une bonne partie exploratoire d'Azeroth. Plus que le joueur, je remercie la personne qui m'a toujours conseillée et rassurée tout au long de ma thèse et qui est si souvent venu me voir. Je remercie également tous les membres des Aes Sedai pour leur bonne humeur constante et leur soutien. J'adresse mes sincères remerciements à Olivier qui a suivi mes travaux presque aussi assidûment que moi. Enfin, merci à Laurent, Numa, Fred, Matthieu, Karim, Sébi, Nicolas, Elsa, Samuel, Greg, Pierrot, Stéphane pour leur soutien et la facilité avec laquelle leur présence m'aura aidée à surmonter les moments les plus difficiles de ma thèse.

Table des matières

Introduction générale	1
1 L'imagerie astronomique	3
1.1 L'imagerie astronomique	3
1.1.1 L'imagerie monobande	3
1.1.2 Spectroscopie	8
1.1.3 Imagerie multibande	9
1.1.4 L'imagerie hyperspectrale	12
1.2 Archivage et gestion de grandes masses de données astronomiques	13
1.3 Traitement de l'image en astronomie	14
1.3.1 Les outils de traitements astronomiques	15
1.3.2 Méthodes avancées de traitement du signal et de l'image appliqué à l'astronomie	16
1.4 Conclusion	19
2 Segmentation markovienne floue	21
2.1 Notations utilisées	23
2.2 Les méthodes de segmentation	23
2.2.1 Méthodes supervisées	24
2.2.2 Méthodes non-supervisées	25
2.3 Segmentation markovienne floue	27
2.3.1 Théorie de l'estimation bayésienne	28
2.3.2 Modèle markovien flou	30
2.3.3 Estimation des paramètres du modèle markovien	37
2.4 Résultats de segmentations	42
2.5 Conclusion	50
3 Détection des galaxies à faible brillance de surface	55
3.1 Introduction	55
3.2 Notations utilisées	57
3.3 Segmentation markovienne par quadarbre	57
3.4 Détection des galaxies LSB	59
3.4.1 Traitements "astronomiques" des observations INT	59
3.4.2 Elimination d'objets dans la carte de segmentation	60
3.4.3 Optimisation des paramètres de chaque ellipse	61
3.5 Résultats de détection	67

3.5.1	Données utilisées	67
3.5.2	Résultats	68
3.5.3	Comparaisons avec la détection de S. Sabatini	71
3.5.4	Comparaisons avec la détection de Sextractor	72
3.6	Conclusion	73
4	Visualisation d'images astronomiques multibandes	77
4.1	Introduction	77
4.2	Notations utilisées	79
4.3	Colorimétrie	79
4.3.1	L'espace RVB	80
4.3.2	L'espace TSL	81
4.4	Réduction et analyse de données	82
4.4.1	L'analyse factorielle discriminante	82
4.4.2	Réduction des données	84
4.5	Première méthode de visualisation colorée	85
4.5.1	Utilisation de l'ACP pour l'axe L	87
4.5.2	Utilisation de l'AFD pour les axes T et S	87
4.5.3	Résultat sur une image simple	89
4.5.4	Résultats sur des images obtenues en télédétection	91
4.5.5	Résultats sur des images astronomiques	93
4.6	Deuxième méthode de visualisation	102
4.6.1	Modèle TSL	103
4.6.2	Résultats	104
4.7	Conclusion	112
5	Réduction-segmentation d'images astronomiques hyperspectrales	115
5.1	Notations	117
5.2	Contexte astronomique	118
5.2.1	Introduction à la physique des galaxies	118
5.2.2	Un univers simulé : GALICS	124
5.3	Réduction-Segmentation de cubes de données hyperspectraux	126
5.3.1	Projection des données	127
5.3.2	La méthode des Mean-Shift	128
5.4	Résultats	134
5.5	Conclusion	143
	Conclusion générale	145
	Bibliographie	151

Introduction générale

L'astronomie est une science qui a toujours fascinée l'homme, que ce soit par l'observation directe du ciel à l'oeil nu ou la découverte de nouveaux systèmes planétaires. Les progrès instrumentaux constants ont permis, dès les premiers jours d'utilisation d'instruments optiques, des découvertes qui ont bouleversées la vision de notre univers. De la découverte de nouvelles planètes toujours plus lointaines dans notre système solaire à l'embarquement de capteurs et d'instruments complexes sur la sonde CASSINI en 2005, la découverte de nouvelles théories astronomiques a toujours conduit à la construction de capteurs/télescopes de plus en plus puissants et sensibles. Les observations terrestres étant bruitées par le passage des photons dans l'atmosphère, le nombre de télescopes mis en orbite n'a cessé de grandir (le célèbre télescope Hubble en est un exemple). Cependant, l'arrivée de l'optique adaptative a permis d'obtenir des images acquises par des observatoires terrestres pour lesquelles l'effet de parasitage atmosphérique est compensé par plusieurs miroirs inclinables pilotés informatiquement en temps réel. De plus les capteurs multispectraux permettent dorénavant d'obtenir un ensemble d'images de la même portion du ciel à des longueurs d'ondes différentes. On assiste ainsi, de nos jours, au passage d'une observation deux dimensions à une observation trois dimensions permettant de découvrir le comportement spectral de l'objet en fonction de la longueur d'onde d'acquisition.

Ces différentes techniques d'acquisition s'accompagnent fréquemment d'inconvénients pour l'astronome. Par exemple, sur des images monobandes (composées d'une seule longueur d'onde), certains objets à rayonnement faible seront en partie masqués par le bruit présent dans l'image. En effet, les capteurs utilisés en imagerie montrent encore leur limite en terme de sensibilité. Dans le cas d'images multispectrales, le principal inconvénient rencontré par la communauté astronomique est la difficulté d'interprétation et de mise en commun de l'information portée par les bandes. De plus, l'augmentation des relevés du ciel par les télescopes terrestres et spatiaux conduit à une abondance de données difficilement quantifiable nommée "avalanche de données". L'astronome se retrouve donc face à une gigantesque masse de données complexes, hétérogènes et distribuées dont l'interprétation peut devenir fastidieuse et délicate dans le cas, par exemple, de données multispectrales. Il est donc nécessaire de proposer à l'astronome un ensemble d'outils facilitant son travail d'interprétation indépendamment du nombre de bandes de l'observation. Il est alors souhaitable de proposer des méthodes de détection d'objets, de segmentation d'observations multispectrales, de visualisation d'images, etc. Cette thèse s'inscrit dans cette optique en ayant pour buts principaux la détection des galaxies à faible brillance de surface ainsi que la segmentation de cubes de données hyperspectraux (dont le nombre de bandes dépasse la cinquantaine) et, accessoirement, la segmentation floue et la visualisation d'images

multispectrales.

La première tâche, de détection des galaxies à faible brillance de surface, consiste à mettre en valeur des objets dont la brillance est inférieure à celle du fond de ciel. Les galaxies LSB (Low Surface Brightness) jouent un rôle important dans notre connaissance de l'évolution et de la formation des galaxies. Elles pourraient être responsables de la masse cachée de l'univers (masse noire) et n'ont été détectées que très récemment grâce, encore une fois, au progrès technologique des capteurs dont la sensibilité a fortement augmentée. Les techniques astronomiques pour effectuer ses détections sont généralement basées sur des seuils successifs (éliminant une partie de l'objet en même temps que le fond de ciel) ou, plus simplement, sur une étude visuelle de l'observation. Ces méthodes montrant rapidement leurs limites, nous proposons un algorithme de détection basé sur une segmentation markovienne de l'observation, qui, par une estimation fine du bruit, fait "ressortir" les objets à faible brillance de surface du fond de ciel. Un ensemble de critères astronomiques est ensuite défini sur l'objet détecté afin de valider son appartenance au type LSB.

Une seconde tâche revient à proposer une segmentation de cubes de données hyperspectraux. En effet, les modèles standards de segmentation mono/multibandes ne sont pas applicables au cas hyperspectral à cause de la "malédiction de la dimensionnalité" (également nommée "phénomène de Hughes"). Le nombre de bandes augmentant, le nombre de pixels dans l'image reste constant et conduit ainsi à un espace clairsemé. Nous avons donc à notre disposition trop peu d'échantillons par rapport à la taille de l'espace pour se livrer à une inférence bayésienne. Dans ce cas, nous pouvons alors considérer une segmentation basée sur des critères spectraux puisque l'imagerie hyperspectrale donne accès à un spectre par position dans l'image. La discrimination entre deux pixels se fera donc sur la troisième dimension spectrale. Nous avons étudié l'utilisation d'une projection couplée à un algorithme d'estimation non-paramétrique de densité de probabilité (algorithme des Mean-Shift), permettant de classifier les pixels en fonction de leur comportement spectral. L'utilisation d'une segmentation markovienne, en dernier lieu, conduit à l'introduction d'une régularisation spatiale de la carte de segmentation spectrale. Cette nouvelle méthode de segmentation est testée et validée sur des images de télédétection en plus d'images astronomiques montrant ainsi la généralité de l'approche.

Une troisième tâche consiste à proposer une segmentation multibande dont l'application répond beaucoup mieux aux besoins des astronomes que les modèles existants. Une approche floue, modélisant le fait qu'un pixel puisse appartenir à une ou plusieurs classes "dures", couplée à la segmentation par champs de Markov est alors définie. Cette approche floue se révèle généralement appropriée à l'imagerie astronomique où les frontières des objets ne sont pas clairement définies et où les corps stellaires sont généralement diffus. L'approche présentée dans ce manuscrit est utilisée pour segmenter des observations monobandes et multibandes.

Enfin, nous proposons une méthode de visualisation d'images multibandes astronomiques. En effet, l'astronome, ayant à disposition une observation multispectrale, requiert une visualisation directe de la contribution de chacune des bandes. Dans le cas d'images composées de trois bandes, une simple affectation de chaque bande aux canaux R, V

et B de l'espace coloré RVB permet de visualiser l'image sous la forme d'une composition colorée. Cependant, lorsque le nombre de bandes dépasse trois, la paramétrisation de l'espace RVB n'est plus directe. Nous proposons donc deux méthodes de visualisation d'images multi/superspectrales (jusqu'à une cinquantaine de bandes environ) basées, pour la première méthode sur une analyse de Fischer et une analyse en composantes principales, puis, pour la deuxième méthode sur une paramétrisation beaucoup plus familière à l'astronome, respectant les couleurs astronomiques de l'objet. Cette composition colorée est effectuée dans l'espace intuitif TSL (Teinte Saturation Luminance) puis convertie dans l'espace RVB pour affichage. Ces deux méthodes ont également été validées sur des images issues du domaine de la télédétection où le problème de visualisation est également rencontré.

Le manuscrit est organisé en cinq chapitres. Le premier débute par une description de l'imagerie astronomique, de ses problématiques et des solutions mises en oeuvre pas la communauté astronomique pour y remédier. Il est en effet indispensable de cerner les problématiques astronomiques afin de faciliter l'interaction entre communauté STIC et astronomes ainsi que le développement de modèles cohérents et applicables à l'imagerie astronomique.

Le deuxième chapitre est consacré à l'introduction du modèle markovien flou. Nous présentons, en première partie, un état de l'art des grandes catégories de méthodes de segmentation puis, dans une seconde partie, introduisons le modèle markovien par champs de Markov flou.

Le troisième chapitre présente une utilisation d'une approche markovienne dans la détection des galaxies à faible brillance de surface. La première partie introduit les problématiques et les nombreux enjeux liés à ces objets particuliers tandis qu'une deuxième partie détaille l'algorithme de détection utilisé.

Le quatrième chapitre présente, dans une première partie, une méthode de visualisation d'images multispectrales basée sur deux méthodes d'analyses de données. La seconde partie est réservée à la présentation d'une deuxième méthode de visualisation beaucoup plus axée sur le système familier d'interprétation des astronomes. La communauté astronomique se retrouve donc dans un système coloré familier, intuitif et facilement interprétable.

Enfin, le dernier chapitre présente une méthode de segmentation spectrale d'images hyperspectrales basée sur une projection des données sur une base de spectres, cette base étant mise à jour dans l'algorithme et contenant les principaux comportements spectraux détectés dans l'image. Cette méthode est également validée sur une image de télédétection.

1 L'imagerie astronomique

Depuis l'invention de la lunette astronomique au XVI^{ème} siècle jusqu'aux relevés astronomiques effectués de nos jours à l'aide de télescopes mis en orbite autour de la terre, la compréhension des mécanismes régissant l'univers et notre système planétaire n'a jamais cessé de fasciner l'homme. Les progrès de l'imagerie astronomique ainsi que l'utilisation de la spectroscopie permettent de se livrer à des études de plus en plus poussées et d'observer de plus en plus loin dans l'univers. L'arrivée de ces nouvelles technologies a toujours bouleversé la vision astronomique permettant, par exemple, la découverte d'un nouveau type d'objet astronomique ou encore, la mise en place d'une nouvelle théorie physique. L'astronomie contemporaine est devenue très complexe et se divise en deux branches. La première regroupe les différentes techniques d'observation ainsi que les disciplines en découlant : radioastronomie, astrométrie, astrophotographie, imagerie... La deuxième concerne les disciplines astronomiques dérivées de l'étude et de l'observation du ciel : astrophysique, astrochimie, l'astrogéologie...

L'astronomie, comme toutes les sciences d'observations, bénéficie de l'amélioration des techniques en électronique, optique, informatique et de distribution de l'information : plus de campagnes d'observation, avalanche de données, traitements automatiques... En effet, l'utilisation d'approches automatiques afin de traiter les observations astronomiques offre une aide précieuse aux astronomes. Ces traitements informatiques montrent de plus en plus leur utilité dans le cas de manipulation de données complexes, hétérogènes ou réparties. Ce chapitre présente ainsi l'état actuel du traitement d'images astronomiques. Une première section définit l'imagerie astronomique ainsi que les différents types de données abordés, dans ce travail, pouvant résulter d'une observation : images, spectres, etc. Le volume de données astronomiques (images, catalogues...) croissant continuellement, la deuxième section présente la notion d'archivage et de gestion de grandes masses de données. Enfin, dans une troisième section, l'utilité de la mise en oeuvre de méthodes de traitements d'images automatisées est introduite.

1.1 L'imagerie astronomique

La diversité des instruments et des chaînes d'acquisition engendre une palette de problématiques à résoudre et amène à développer différentes stratégies d'analyses d'images.

1.1.1 L'imagerie monobande

L'imagerie monobande consiste à obtenir l'image d'un objet astronomique en utilisant un dispositif optique plus ou moins complexe (figure 1.1).

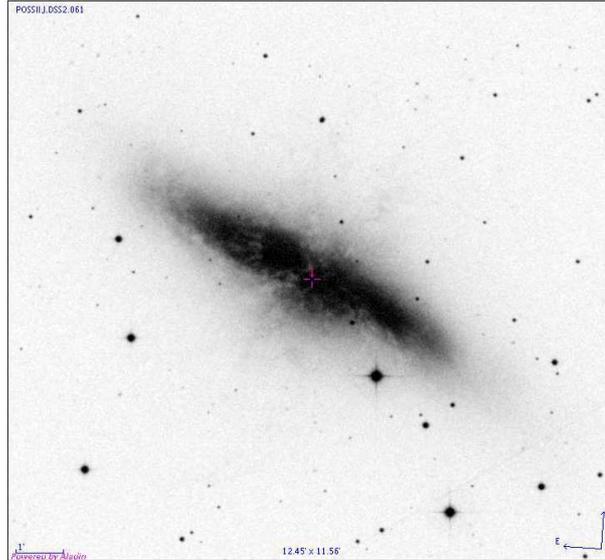


FIG. 1.1 – Galaxie M82, DSS2, Bande J

Les modes d'acquisition de ces images sont variés : plaque photographique, appareil photographique, webcam (ces deux derniers modes d'acquisition étant généralement réservés aux astronomes amateurs à cause du manque de précision de l'instrumentation optique les constituant), capteur CCD, télescope radio... L'objet astronomique est observé au travers d'un filtre (figure 1.2) qui permet de sélectionner une plage de longueurs d'ondes d'acquisition. On peut faire alors la distinction entre les filtres à bande étroite permettant de sélectionner une longueur d'onde unique des filtres à bande large couvrant une plage de longueurs d'ondes.

Les plaques photographiques utilisées précédemment par les astronomes professionnels sont aujourd'hui devenues obsolètes avec l'avènement des capteurs CCD (Charged Couple Device - dispositif à transfert de charge) ainsi que des caméras grand champ (mosaïque de CCD). Ces capteurs offrent une plus grande sensibilité ainsi qu'une plus grande surface d'acquisition que l'imagerie argentique. Au début des années 1980, les premières caméras CCD sont utilisées en imagerie astronomique. En imagerie CCD, la lumière vient frapper une matrice de cellules photosensibles (les pixels). Dans le processus d'acquisition, le capteur CCD est situé à l'un des foyers du télescope. L'image formée par l'instrumentation optique est alors projetée sur la matrice du CCD. Chaque pixel frappé par un photon lumineux fournit alors une réponse électrique dont l'intensité est proportionnelle au nombre de photons rencontrant la cellule durant le temps d'exposition. Un convertisseur analogique/numérique permet ensuite de transformer ces intensités électriques en valeurs numériques proportionnelles au flux de photons. La très grande sensibilité des capteurs CCD présente un certain nombre d'inconvénients. En effet, dans tout matériau, les électrons sont excités en fonction de la température. Ainsi, dans une caméra CCD, l'agitation des électrons crée un certain nombre de charges parasites appelées *charges thermiques*. Un refroidissement doit donc être mis en place pendant le processus d'acquisition.

De plus, chacun des pixels du CCD ne possédant pas la même sensibilité, il est

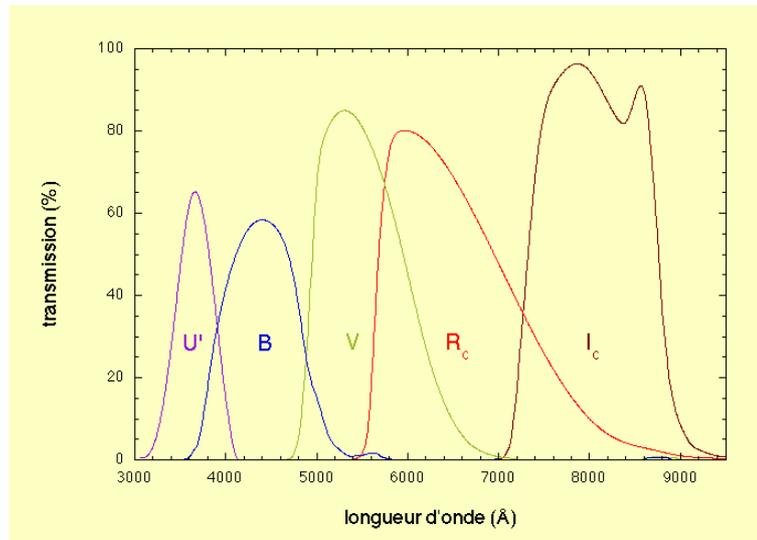


FIG. 1.2 – Courbes de transmission des filtres utilisés pour l'imagerie directe à l'Observatoire de Haute Provence (OHP). Ces filtres permettent de mesurer des flux allant du proche UV au proche infrarouge.

nécessaire de prendre en compte cette caractéristique en acquérant, avant observation, l'image d'une zone uniforme (correspondant à une zone du ciel sombre, sans objets brillants). L'image ainsi obtenue est l'image de Plage de Lumière Uniforme (PLU ou *flat-field en anglais*). Une deuxième acquisition avant toute observation doit être également effectuée afin d'éliminer le bruit de lecture des électrons parasites. Elle consiste à acquérir une image de précharge (*bias en anglais*) en ayant l'obturateur du télescope fermé (pose courte). Enfin, une dernière étape similaire à la précédente excepté le temps de pose qui doit être aussi long que le temps de pose d'imagerie, permet de tenir compte du signal thermique (*darkfield en anglais*). On peut alors écrire :

$$\text{Image Finale} = \frac{\text{Image Brute} - \text{Dark field}}{\text{Flat Field} - \text{bias}}$$

L'obtention d'une image monobande est donc constituée d'un ensemble d'étapes permettant de corriger les défauts liés à l'optique du système.

D'autres d'artefacts d'acquisition peuvent également avoir une influence sur la qualité de l'image observée. C'est le cas notamment lorsque l'objet observé est très lumineux et que le capteur CCD est saturé pendant l'acquisition (figure 1.3).

Une étoile est un objet ponctuel. Cependant, on remarque, dans les images astronomiques, l'apparition d'un halo plus ou moins brillant entourant l'objet. Ce halo est une conséquence directe de la PSF (*Point Spread Function* ou fonction d'étalement/d'appareil) du capteur CCD. La PSF est une fonction définissant l'étalement dû à la turbulence atmosphérique ainsi qu'aux réflexions des rayons lumineux dans le télescope. Le phénomène induit sur l'observation par la PSF est généralement modélisé par une convolution de l'image par une fonction (figure 1.4). Une estimation de la PSF, parfois délicate car elle peut varier selon la position dans l'image, permet alors de déconvoluer l'image. Généralement, dans les traitements astronomiques, cette déconvolution n'est pas systé-

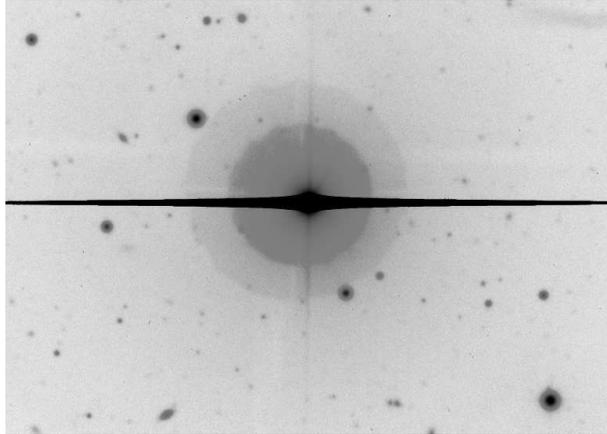


FIG. 1.3 – Saturation du capteur CCD à cause d'une étoile très brillante.

matiquement effectuée mais l'interprétation de l'image prend alors en compte ce facteur de convolution.

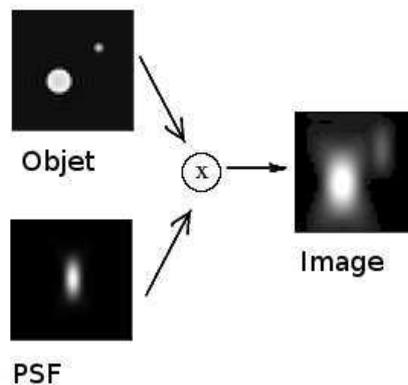


FIG. 1.4 – Convolution de l'objet par la fonction d'étalement

L'imagerie monobande permet de se livrer à des études poussées sur l'objet :

- l'étude morphologique permet de déduire, à partir de l'image, la forme générale d'un objet et ainsi de le classer. C'est le cas, par exemple, dans le cas de la classification morphologique de galaxies dont la forme permet la caractérisation en plusieurs types (spirale, elliptique, irrégulière... figure 1.5) ;
- l'étude des propriétés de l'objet : l'image monobande est acquise autour d'une longueur d'onde centrale λ . L'astronome, peut, à l'aide de filtres disposés en amont du capteur CCD, sélectionner la longueur d'onde d'intérêt pour son étude. Ainsi, la connaissance de cette information de longueur d'onde permet de dégager des comportements propres à cette longueur d'onde et de déduire ainsi des propriétés physiques de l'objet.

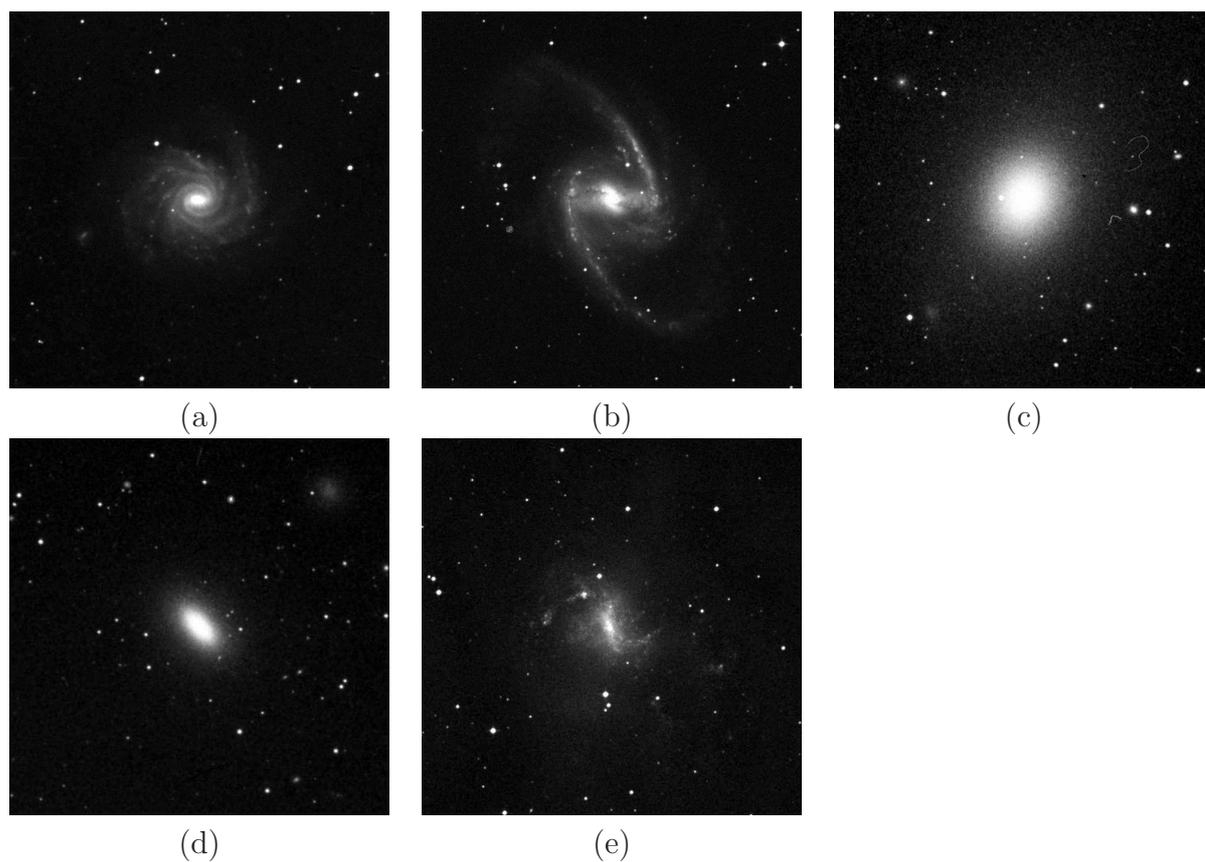


FIG. 1.5 – Différents types de galaxies dans le domaine du visible. (a) : galaxie spirale NGC1232. (b) : galaxie spirale barrée NGC1365. (c) : galaxie elliptique M49. (d) : galaxie lenticulaire NGC3377. (e) : galaxie irrégulière NGC1313

1.1.2 Spectroscopie

La spectroscopie est un domaine de la physique permettant d'obtenir le spectre d'un objet astronomique (figure 1.6) au moyen d'un spectrographe.

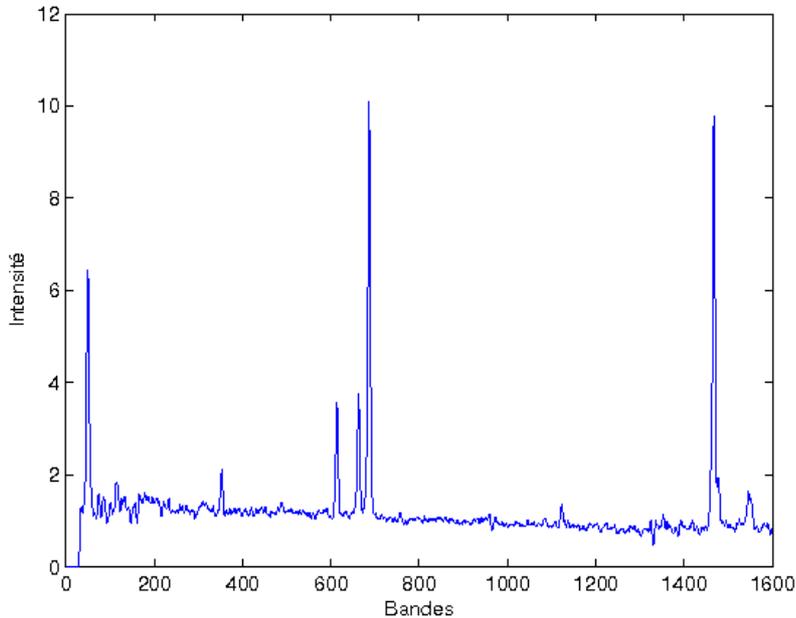


FIG. 1.6 – Spectre d'une galaxie

L'échantillonnage du spectre ainsi que la plage de longueurs d'ondes couverte dépendent de l'instrumentation du spectrographe. En spectroscopie, l'étude porte sur un spectre intégré sur tout ou partie de l'objet avec ou sans résolution spatiale et non plus sur une image résolue spatialement (la morphologie de l'objet est donc perdue).

Le spectre de tout objet astronomique contient toute l'information relative à sa composition chimique et physique, ce qui renseigne notamment sur l'histoire de sa formation et de son évolution. Un spectre se compose en général d'un continuum et d'un ensemble de raies d'émission et/ou d'absorption. Ces raies sont formées par l'interaction des atomes constitutifs de l'objet et du bain de photons. Lorsque l'électron d'un atome est excité, il libère, en se désexcitant (changement de son niveau d'énergie), un photon produisant ainsi une raie d'émission dont la longueur d'onde est caractéristique de l'atome et du niveau d'excitation de l'électron. Les atomes d'un nuage de gaz situé sur le trajet de la lumière vont capturer des photons, donnant naissance à une raie d'absorption. Par exemple, dans les régions H_{II} (atome H_I ionisé), la désexcitation des électrons va produire une série de raies caractéristiques dont H_α (raie de la série de Balmer lorsque l'électron de l'hydrogène transite entre le troisième niveau d'énergie et le second) dans le rouge à 6563\AA est la principale dans le domaine du visible. L'étude du spectre d'un objet en rotation (une galaxie par exemple) permet d'obtenir des informations sur sa vitesse en mesurant le décalage des raies due à l'effet Doppler (effet global). Ce décalage spectral est très important dans l'analyse spectrale et sera détaillé dans un chapitre ultérieur. Il se détermine

en comparant le spectre étudié avec un spectre de référence connu. L'information sur le décalage des raies permet d'obtenir une carte de vitesses de l'objet (petit décalage de raies à l'intérieur même de l'objet). La largeur des raies renseigne également sur l'abondance et la température de l'élément considéré. L'inconvénient, dans la spectroscopie, est la perte de la résolution spatiale au profit de la résolution spectrale. L'information en longueur d'onde, ou fréquence ou énergie est donc riche sur l'axe spectral mais mal localisée en position pour les données spectroscopiques. Une approche multibande couplant l'imagerie à la spectroscopie permet d'acquérir à la fois les deux types d'informations spectrales et spatiales.

1.1.3 Imagerie multibande

L'imagerie multibande consiste à obtenir un ensemble d'images (une dizaine au maximum appelées *bandes*) du même objet mais à des longueurs d'ondes différentes. Ainsi à chaque position spatiale dans l'image correspondra une information spectrale. L'image passe donc de deux dimensions à trois dimensions par l'ajout de la dimension spectrale (1.7).

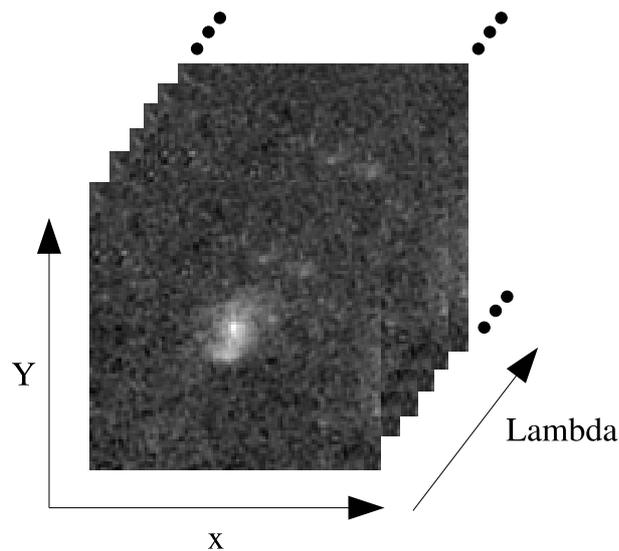


FIG. 1.7 – Les trois dimensions d'un cube de données multibande

L'approche multibande permet, par exemple dans le cas de la classification de galaxies, de mettre en place une classification spectromorphologique portant sur la forme spatiale des objets ainsi que sur les caractéristiques spectrales. La troisième dimension spectrale introduit un ensemble d'informations supplémentaires afin de différencier les différents types d'objets.

La confrontation visuelle des bandes du cube permet également de visualiser les contributions des objets observés selon la longueur d'onde. Ainsi dans l'ultraviolet, une galaxie se manifeste par ses zones de formations stellaires (discontinuité de la structure) alors que dans l'infrarouge proche, on observe la structure globale de l'objet au travers des étoiles anciennes ainsi que par l'émission du continuum de la poussière (figure 1.8).

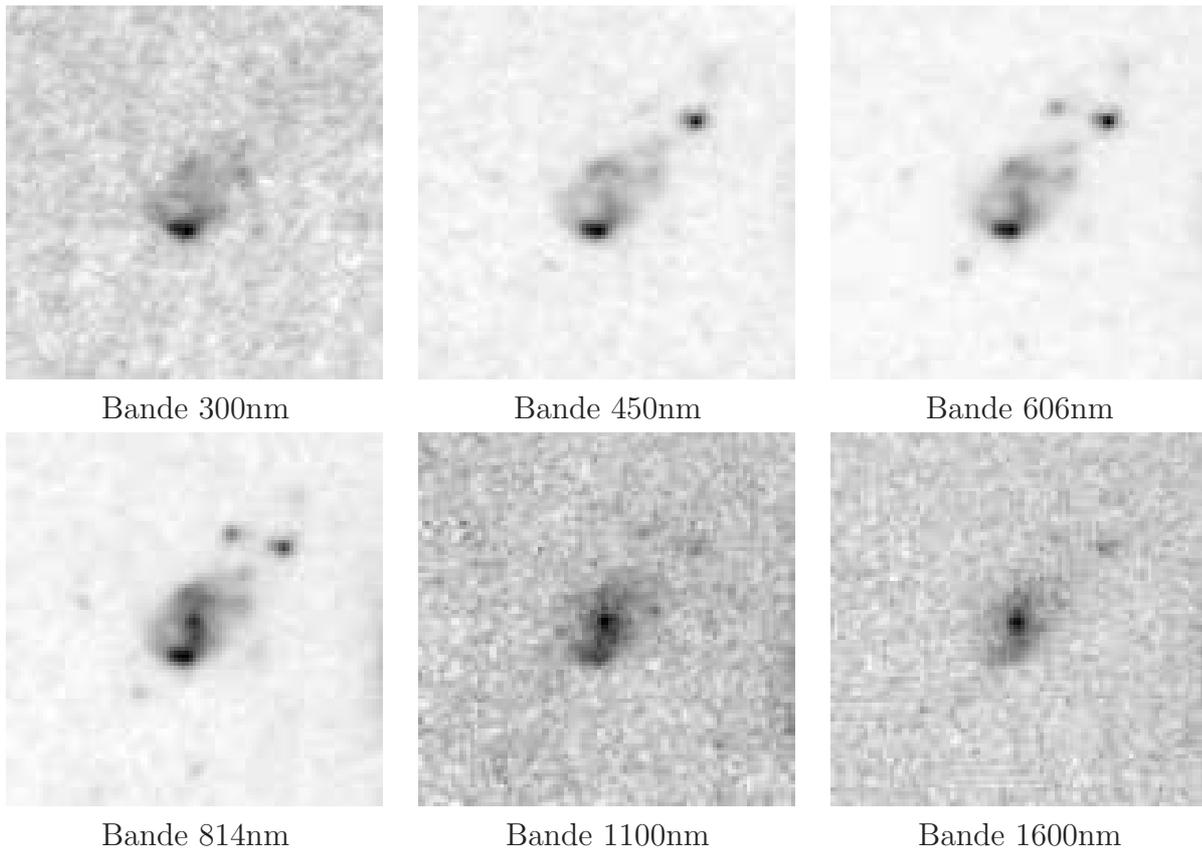


FIG. 1.8 – Galaxie de la collection d'images du Hubble Deep Field HDF-474 - 6 bandes. Taille 101×101 pixels. Pour chaque longueur d'onde, la galaxie présente des aspects différents : zones de formation stellaire dans l'ultraviolet et structure globale dans l'infrarouge proche

Dans le cas de données composées de trois bandes, il est possible de projeter les trois images dans un espace coloré afin de visualiser simultanément les trois bandes sur une seule image. L'espace coloré *RVB* (Rouge Vert Bleu) est généralement utilisé car il respecte l'ordre des longueurs d'ondes, *i.e.*, les petites (*resp.* grandes) longueurs d'ondes seront assignées au canal Bleu (*resp.* Rouge) et le canal Vert contiendra l'image intermédiaire. Cette visualisation résume l'information spectrale et spatiale sur une carte unique rapidement interprétable visuellement (figure 1.9 et figure 1.10). Cependant, lorsque le nombre de bandes de l'observation dépasse 3, la composition *RVB* n'est alors plus applicable et il convient de proposer de nouvelles méthodes de visualisation (*cf.* chapitre 4).

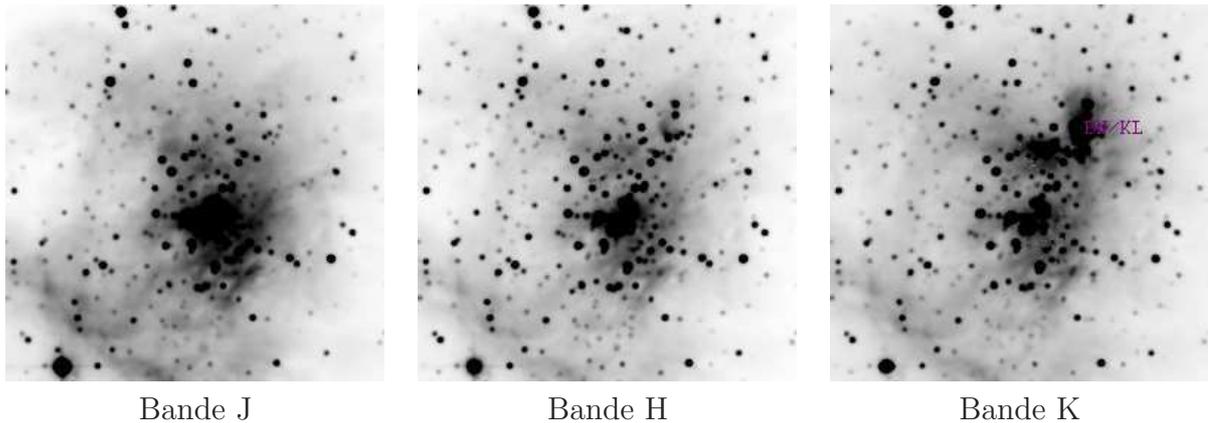


FIG. 1.9 – ORION : 3 bandes 2MASS. Taille : 256×256 pixels.



FIG. 1.10 – ORION : Composition colorée dans l'espace *RVB* de la figure 1.9. Cette méthode permet de visualiser clairement la contribution de chacune des bandes originales.

L'imagerie multibande permet d'obtenir un cube dont la résolution spatiale est très grande au détriment de la résolution spectrale. Ainsi le nombre de bandes de tels cubes ne dépassera généralement pas la dizaine. La spectroscopie intégrale de champ nous permet d'accéder à des cubes super/hyperspectraux dont le nombre de bandes sensiblement plus grand peut atteindre, de nos jours, 500 éléments de résolutions spectraux.

1.1.4 L'imagerie hyperspectrale

En traitement du signal, la distinction entre imagerie superspectrale et hyperspectrale est arbitraire et s'effectue en fonction du nombre de bandes de l'observation. On pourra donc classer les cubes de données de la sorte :

- une bande : image monobande ;
- entre 2 et 10 bandes : image multibande ou multispectrale ;
- entre 10 et 50 bandes : image superspectrale ;
- au-delà de 50 bandes : image hyperspectrale.

On considère, dans la suite de ce chapitre, que le terme "imagerie hyperspectrale" regroupe également l'imagerie superspectrale.

L'imagerie hyperspectrale est un domaine de l'imagerie astronomique relativement récent. En effet, la technologie des capteurs ne permettait pas encore jusqu'à quelques années, d'obtenir de tels cubes de données. Elle donne accès à un cube de données où l'axe des longueurs d'ondes est échantillonné très finement. Il est ainsi possible, pour les besoins d'une étude particulière, d'étudier très précisément le voisinage d'une raie d'émission ou d'absorption ou, au contraire, d'étudier une large plage de longueurs d'ondes. Cependant, cette grande résolution spectrale implique une faible résolution spatiale due aux limites technologiques actuelles. Certains cubes peuvent ainsi être de taille $32 \times 32 \times 360$ pixels rendant toute étude morphologique délicate.

Le spectrographe intégral de champ MUSE¹ est un instrument qui équipera, en 2011, le VLT (Very Large Telescope) au Chili. Grâce à sa capacité sans précédent pour observer l'univers en volume et en profondeur, MUSE devrait permettre aux astronomes des avancées dans l'étude de la formation et de l'évolution des objets astronomiques. Les cubes de données issus de MUSE sont de taille $2400 \times 2400 \times 3000$ pixels.

Le volume et la complexité sans précédent de ces cubes de données soulèvent d'emblée le problème du traitement des observations. En effet, la masse considérable d'information rend les traitements délicats, fastidieux et coûteux en temps de calcul. L'interprétation d'un cube de données issu de MUSE, par exemple, nécessite le développement de méthodes de traitements spécifiques aux cubes hyperspectraux. En effet, les méthodes généralement appliquées sur des images multibandes ne sont pas directement applicables et adaptables au cas hyperspectral. Une approche généralement retenue consiste à réduire le cube de données en un ensemble de bandes réduites qui synthétise l'information essentielle présente dans le cube original. Néanmoins, sur un cube de 3000 bandes, le nombre de bandes réduites risquent d'être encore très élevé et de nécessiter ainsi des post-traitements complémentaires. L'archivage et la mise à disposition à la communauté astronomique de ces données présentent également un défi en terme de volume de données : 64Go par cube typiquement pour des valeurs codées sur des flottants à 32 bits.

¹<http://muse.univ-lyon1.fr/>

Parallèlement à la taille des données d'observations, la diversité des instruments et des capteurs utilisés conduit logiquement à une imagerie hétérogène dans laquelle l'astronome peut sélectionner des observations d'origines diverses : radiotélescope, spectroscopie, imagerie optique, imagerie spectrale....

Le nombre élevé de *surveys* (relevé d'une partie du ciel par un télescope) conduit alors à un nombre croissant d'images mises à disposition (les images astronomiques étant libres de droit). Il se pose la question d'une architecture permettant de stocker, rechercher, télécharger et parfois traiter les données astronomiques. Le Centre de Données astronomiques de Strasbourg (CDS) est un exemple de structure facilitant le partage de données dans la communauté astronomique.

1.2 Archivage et gestion de grandes masses de données astronomiques

L'avalanche de données est aussi manifeste pour des données d'interprétations telles que les catalogues : USNO (le plus grand catalogue disponible actuellement en ligne) qui compte plus d'un milliard d'objets, SDSS qui devrait compter une centaine de millions d'objets avec, pour chacun, 1500 mesures, puis les archives en ligne des observatoires, réparties sur toute la planète, contiennent des dizaines, voire des centaines, de teraoctets de données (images, spectres, séries temporelles). La nécessité de tirer tout le potentiel scientifique de ces grands projets et le défi de traiter et distribuer de très grandes masses de données a conduit ces dernières années au développement du projet "d'observatoire virtuel astronomique" : *Il s'agit d'un projet visant à faciliter et coordonner le développement des outils, des protocoles et des collaborations nécessaires pour réaliser tout le potentiel scientifique des données astronomiques dans la décade à venir* (traduit du National Virtual Observatory White Paper, juin 2000). Deux conférences internationales fondatrices, qui se sont tenues en 2000 des deux côtés de l'Atlantique, Virtual Observatories of the Future au California Institute of Technology (Pasadena), et Mining the Sky à Garching, siège de l'Observatoire Austral Européen (ESO), ont permis d'explicitier les besoins scientifiques et de poser les bases des avancées nécessaires. De nombreux projets ont été proposés et acceptés en 2001 dans des contextes divers pour l'élaboration du cahier des charges ou des actions de Recherche et Technologie. Les principaux sont Astrophysical Virtual Observatory en Europe, AstroGrid, projet e-Science britannique, National Virtual Observatory, aux Etats-Unis (projet NSF dans le domaine des sciences de l'information). De nombreux autres projets nationaux ont démarré, en Allemagne, au Canada, en Australie, en Inde, au Japon, etc. L'Observatoire Virtuel fédère également des données et des ressources calculs pour les définitions et la mise en oeuvre de standards d'interopérabilité et les rendre visibles via des répertoires standardisés. La construction de l'Observatoire Virtuel est un projet majeur de la communauté astronomique de cette décennie.

Le Centre de Données astronomiques de Strasbourg (CDS) est un centre de données dédié à la collection et à la distribution dans le monde entier de données astronomiques. Il héberge la base de référence mondiale pour l'identification d'objets astronomiques (SIMBAD) et ses missions consistent à rassembler toutes les informations utiles, concernant les objets astronomiques et disponibles sous forme informatisée : données d'observations produites par les observatoires du monde entier, au sol ou dans l'espace; distribuer

les résultats dans la communauté astronomique ; conduire des recherches utilisant ces données.

Le CDS a développé le logiciel Aladin²[11] qui est un portail permettant la navigation et l'interprétation de données d'imageries, de catalogues et de spectres. Cet outil est connecté à d'autres services du CDS : VizieR³ (bases de catalogues) et Simbad⁴ (base de données d'objets issues des archives bibliographiques en ligne). Il permet de sélectionner, comparer, valider des données hétérogènes dans un environnement convivial pour l'astronome (figure 1.11).

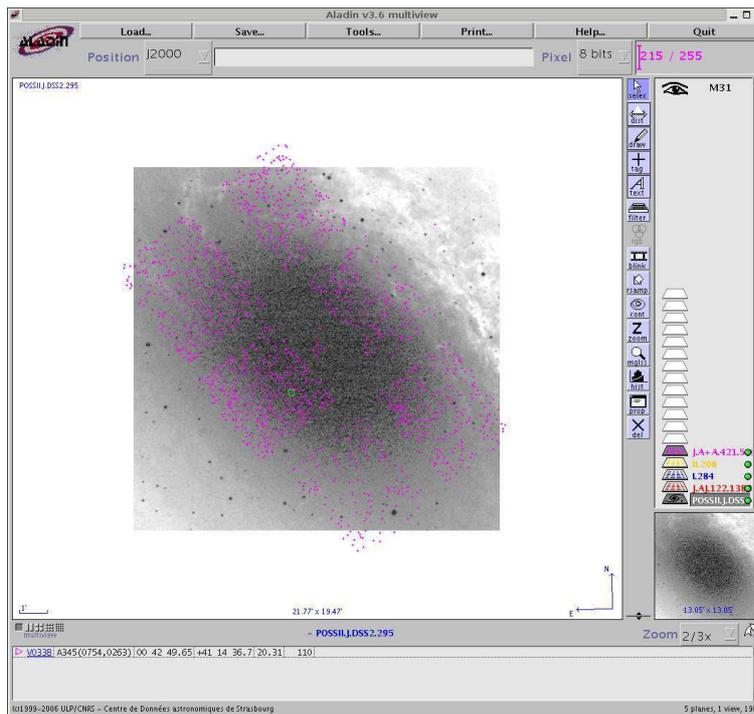


FIG. 1.11 – L'interface du logiciel Aladin

La masse de données disponible conduit alors logiquement à l'apparition de méthodes automatiques de traitements de données encapsulées dans des logiciels de traitements astronomiques. Ces logiciels proposent un ensemble de traitements, sur les images, éprouvés par les astronomes. Toutefois ils ne sont pas tous adaptés aux différents types de données (multibandes, hyperspectrales...).

1.3 Traitement de l'image en astronomie

Les premières interprétations des images astronomiques furent uniquement visuelles. En effet, la technologie informatique en place lors de l'obtention des premières images du ciel n'était pas utilisable pour un traitement automatique de celles-ci. Au fur et à

²<http://aladin.u-strasbg.fr/aladin.gml>

³<http://vizier.u-strasbg.fr/>

⁴<http://simbad.u-strasbg.fr/Simbad>

mesure des avancées informatiques, les logiciels de traitements automatiques des données ont considérablement simplifié l'interprétation des observations pour la communauté astronomique. De plus, depuis quelques années, quelques modèles spécifiquement dédiés ou adaptés pour le traitement d'images astronomiques ont vu le jour. Certains de ces modèles, pouvant être motivés au départ par des considérations théoriques sur les images, restent peu familiers à la communauté astronomique. Il est ainsi nécessaire de proposer aux astronomes des outils d'utilisation simple et intuitive basés sur des modèles dont l'utilisation est délicate sans connaissance théorique de leur fonctionnement. Le traitement de l'image astronomique actuel peut donc se diviser en deux grandes catégories :

- les outils purement astronomiques, familiers aux astronomes ;
- les applications développées par la communauté STIC basées sur une modélisation avancée peu connue par la communauté astronomique.

Dans le deuxième cas, le développement d'applications astronomiques par des chercheurs de la communauté STIC nécessite une forte interaction entre les deux parties de façon à diffuser les approches du traitement du signal auprès des astronomes et à sensibiliser les analystes du signal aux problèmes spécifiques de l'astronomie. Cette interaction entre les deux communautés est très souvent riche et conduit la communauté STIC à entrer dans un premier temps dans la problématique des astronomes, puis de proposer un outil répondant à leurs besoins.

1.3.1 Les outils de traitements astronomiques

La communauté dispose de logiciels fournissant un ensemble d'outils généraux pour la réduction (au sens astronomique du terme, *i.e.*, offset, flatfield...) ou l'analyse d'images astronomiques. Le logiciel ESO-MIDAS⁵ (European Southern Observatory Munich Image Data Analysis System) propose un grand nombre de "packages" permettant entre autres :

- l'affichage d'images ;
- l'affichage de graphiques pour la présentation des données et des résultats ;
- le traitement d'images général : opérations arithmétiques basiques, filtrage, échantillonnage, interpolation, extraction, transformée de Fourier...

ESO-MIDAS est un outil libre de droit (sous licence GPL) et assez répandu dans la communauté astronomique.

IRAF⁶ est également un logiciel structuré en collections de programmes dédiés soit au traitement d'images en général, soit aux traitements (réduction, calibration) de données d'un régime de longueur d'onde spécifique : données optiques du Hubble Space Telescope, données X Chandra ou ROSAT par exemple.

Un certain nombre de problèmes particuliers de l'astronomie ont donné lieu à des outils spécifiques. C'est le cas de la détection de sources pour laquelle SExtractor est un outil de choix⁷. SExtractor est développé par E. Bertin à l'IAP (Institut d'Astrophysique de Paris) et permet de construire un catalogue d'objets à partir d'une image astronomique. Il permet également d'obtenir une carte de segmentation de l'observation, une carte de fond, d'effectuer des seuillages afin d'éliminer les objets très brillants ou de filtrer le bruit présent dans l'image. SExtractor est performant et rapide (sur une image de taille

⁵<http://www.eso.org/projects/esomididas/>

⁶<http://iraf.noao.edu>

⁷http://terapix.iap.fr/rubrique.php?id_rubrique=91/

4100 × 2048 la détection de plusieurs centaines d'objets ne prend que quelques secondes sur un ordinateur équipé d'un processeur PIV 2,6Ghz) mais ne permet généralement pas de détecter correctement les sources faibles aux limites du bruit.

Pour l'analyse de spectres, notamment pour le calcul du redshift photométrique z d'origine cosmologique, il existe des outils tel que HyperZ⁸ et LE PHARE⁹ (PHotometric Analysis for Redshift Estimations). Cependant leurs applications sont restreintes aux spectres globaux de chaque objet et non sur des spectres d'objets résolus spatialement.

Le logiciel MVM¹⁰(Modèle de Vision Multiéchelle), développé par E. Slézak et A. Bijaoui à l'Observatoire de la Côte d'Azur de Nice, permet de décomposer une image astronomique en un ensemble d'images multi-échelles. Les échelles grossières font apparaître l'objet dans sa globalité tandis que les échelles fines font ressortir les plus petits détails de la structure.

Enfin, le logiciel Aladin permet d'analyser les résultats en proposant un ensemble d'outils permettant notamment la comparaison avec des catalogues existants, la superposition sur des observations différentes, etc.

Les différents types d'observations astronomiques se traduisent par l'apparition de problématiques complexes que certains des logiciels astronomiques ne peuvent résoudre. Par exemple, dans le cadre de l'imagerie hyperspectrale, il est nécessaire de fournir des outils intégrant les deux types d'informations : spatiale et spectrale. De plus, étant donnée la masse de données à la disposition de l'astronome, il est utile de proposer des outils automatiques d'analyse performant et réalisant des traitements spécifiques à une problématique qui lui est propre.

1.3.2 Méthodes avancées de traitement du signal et de l'image appliqué à l'astronomie

Les modèles du traitement de l'image applicables à l'astronomie sont nombreux et font intervenir de nombreuses disciplines : mathématiques, statistiques, traitement du signal, morphologie mathématique, intelligence artificielle... Les différents champs couverts par ces méthodes vont de la segmentation des observations à la réduction de données. La grande quantité de méthodes de traitement d'images astronomiques rend le travail de l'astronome complexe. Il doit, en fonction de sa problématique, se diriger vers l'une ou l'autre méthode afin d'espérer obtenir un résultat satisfaisant. Ces méthodes étant généralement complexes, la plateforme AÏDA, développé au CDS de Strasbourg par J.J. Claudon offre une interface en ligne et intuitive afin que l'astronome puisse effectuer des traitements complexes de manière WYSIWYG (*What You See Is What You Get*). Cette interface propose d'effectuer une série de tâches dans une interface graphique permettant le positionnement et l'enchaînement de blocs réalisant des traitements spécifiques.

1.3.2.1 Segmentation des observations

La segmentation d'une observation astronomique consiste à regrouper les zones de l'image en classes homogènes. Cette segmentation peut s'effectuer sur des critères nom-

⁸<http://webast.ast.obs-mip.fr/hyperz/>

⁹http://www.lam.oamp.fr/arnouts/LE_PHARE.html

¹⁰<http://www.obs-nice.fr/paper/bijaoui/pagemvm.html>

breux comme par exemple :

- des critères de distance de comportements entre pixels ;
- des critères spatiaux entre pixels voisins ;
- des critères spectraux dans le cadre d'images multibandes.

La segmentation markovienne, par exemple, se fonde sur deux hypothèses :

- similarité des comportements dans un voisinage ;
- modélisation des lois statistiques (loi gaussienne par exemple) de la distribution de la luminosité des pixels.

Les modèles markoviens se divisent en plusieurs catégories :

- les champs de Markov se caractérisent par une corrélation forte entre un pixel et ses 8 voisins ;
- les chaînes de Markov transforment l'image 2D en une chaîne 1D à l'aide d'un parcours d'Hilbert-Peano. Ainsi la classe d'un pixel dépend uniquement de son voisin dans la chaîne ce qui réduit l'expression de la dépendance inter-pixels ;
- le quadarbre markovien considère un voisinage spatial mais en échelle. L'observation est ainsi décomposée en une pyramide dans laquelle chaque étage correspond à un niveau de détail.

Ces différents modèles statistiques seront décrits au fur et à mesure des chapitres de ce document.

La segmentation généralement utilisée en astronomie consiste à seuiliser l'observation en prenant le risque de supprimer l'information enfouie dans le bruit. Les modèles markoviens, par une estimation fine des paramètres du bruit, permettent de dégager les objets noyés dans le bruit et le considère comme porteur d'information. Le chapitre suivant examine un ensemble de méthodes couramment utilisées en segmentation d'images. Ces méthodes sont cependant peu applicables à l'astronomie où les objets répondent à des contraintes bien particulières (faible dynamique, frontières floues conduisant à des objets aux contours diffus...).

1.3.2.2 Réduction de la dimensionnalité des données

La réduction de données s'applique aux cubes super et hyperspectraux. Elle consiste à synthétiser un cube de données de grande taille sous la forme d'une image dont le nombre de bandes est réduit tout en gardant le maximum d'informations présentes dans le cube original. Il ne s'agit donc pas ici de compresser le cube pour réduire sa taille sur un disque dur, mais d'effectuer une étape de réduction préalable facilitant l'interprétation ou l'utilisation des données dans un modèle n'acceptant qu'un nombre de bandes limité. Les principales méthodes utilisées consistent à projeter les données dans un espace maximisant un critère donné. Par exemple, l'analyse en composantes principales (ACP) projette les données dans un espace maximisant la variance entre ses composantes tandis que l'analyse en composantes indépendantes (ACI) projette les données dans un espace maximisant la non-gaussianité des données. Cependant, ces méthodes restent parfois inadaptées à cause d'un manque d'adaptation entre le modèle et les données. Par exemple, pour l'ACP, il n'est pas certain que la variance permette de discriminer au mieux l'information dans le cube original. Le cube réduit sera donc difficilement interprétable.

Une méthode utilisée en spectroscopie ou en imagerie hyperspectrale consiste à étudier la position des raies d'émission/absorption dans les différents spectres constituant l'ob-

jet. A cause de l'effet Doppler, la détermination du décalage des raies inter-objets et intra-objet renseigne sur le champ de vitesse de l'objet considéré. La méthode principalement utilisée pour mesurer ce décalage consiste à représenter le spectre de l'objet sous la forme d'un mélange de lois (lois gaussiennes principalement). Un mélange de g fonctions gaussiennes est défini de la sorte :

$$G = \sum_{i=1}^g \pi_i \times \mathcal{N}(\mu_i, \sigma_i) \quad (1.1)$$

où g est le nombre de gaussiennes et où pour chacune d'elles π_i, μ_i, σ_i sont respectivement la pondération, la moyenne et l'écart-type et $\sum_{i=1}^g \pi_i = 1$.

Chaque raie se voit donc définie par un triplet (π_i, μ_i, σ_i) permettant la comparaison entre raies. De plus, la connaissance de la largeur à mi-hauteur de la gaussienne ainsi que de son amplitude renseigne sur la température et l'abondance de l'élément responsable de cette raie.

Plusieurs méthodes de réduction sont décrites succinctement dans le chapitre 4 et une nouvelle méthode de réduction de données préalable à une segmentation spectrale est présentée dans le chapitre 5.

1.3.2.3 Visualisation d'images multibandes

Lorsque l'astronome traite des données multibandes, la visualisation et la comparaison de l'information portée par chacune des bandes de l'observation est ardue. Il est ainsi utile d'élaborer des méthodes de visualisation de données, synthétisant l'information de l'image originale dans une image colorée. Il n'existe, pour l'instant, que très peu de méthodes de visualisation et aucune directement applicable à l'astronomie et ses problématiques. Nous proposons, dans le chapitre 4, deux méthodes de visualisation appliquée à l'imagerie astronomique permettant de faciliter le travail de l'astronome lorsqu'il traite des données multibandes.

1.3.2.4 La plateforme AÏDA

AÏDA (Astronomical Image processing Distribution Architecture) a été développée afin de proposer à la communauté astronomique un accès rapide et intuitif aux méthodes et modèles développés au sein de l'équipe PASEO¹¹ du LSIIT à Strasbourg. Cette plateforme propose, sous la forme d'une interface graphique accessible en ligne, un ensemble de traitements basiques ou complexes que l'astronome peut enchaîner dans une chaîne de tâches. Ainsi, il peut envisager d'effectuer une réduction de données, puis une segmentation des données réduites sans se préoccuper du lien entre les deux méthodes. Il pourra alors récupérer une carte de segmentation ainsi qu'un ensemble de paramètres décrivant les opérations effectuées durant l'exécution de la chaîne de tâches. Le but de cette plateforme est donc de proposer un ensemble de "boîtes noires" réalisant un traitement complexe que l'astronome pourra enchaîner à l'aide d'un système intuitif de "Drag'n Drop" au travers de l'interface graphique mise à sa disposition. La partie calcul est effectuée sur un serveur dédié et l'utilisateur peut télécharger les résultats de ces traitements. Cette plateforme a été développée par J.J. Claudon au CDS de Strasbourg dans le cadre de l'action concertée

¹¹<http://lsiit-miv.u-strasbg.fr/paseo/>

incitative MDA (Masse de Données Astronomiques), cadre dans lequel se situe également cette thèse.

1.4 Conclusion

Les problématiques rencontrées en astronomie sont nombreuses et complexes. La masse de données mise à disposition de l'utilisateur est gigantesque et le traitement automatique de celles-ci devient nécessaire. Les différents types de données pouvant être acquis par un observatoire ou un télescope mis en orbite conduisent toutes au développement de méthodes dédiées et inadaptées lorsqu'elles sont appliquées sur des images de types différents. Il est en effet inconcevable d'imaginer un modèle s'appliquant indifféremment sur une image monobande et sur une image hyperspectrale de 3000 bandes comme cela sera le cas avec le projet MUSE. La communauté STIC s'est donc tournée vers l'imagerie astronomique, comme cela avait été le cas précédemment avec la télédétection, afin de proposer des méthodes facilitant le travail d'interprétation de l'astronome. Cependant, la collaboration entre astronomes et traiteurs d'images n'est pas immédiate. En effet, les domaines mis en oeuvre sont radicalement différents et le traiteur d'images se doit de comprendre et d'appréhender la problématique de l'astronome afin qu'ils puissent proposer ensemble une méthode adaptée. La barrière du vocabulaire entre les deux communautés est également importante. Par exemple, lorsque l'astronome parle de réduction, il se réfère à l'utilisation d'un offset, d'un flatfield afin d'obtenir une image exempte d'artefacts à la suite d'une observation, tandis que le traiteur d'images se réfère automatiquement à une réduction du nombre de bandes d'un cube hyperspectral. Cela explique la nécessité d'une interaction forte entre l'astronome et le chercheur, puis en phase finale, d'une validation des résultats obtenus.

L'interaction entre les deux communautés pourrait bénéficier du contexte de développement de l'Observatoire Virtuel et augmenter la diffusion des méthodes développées en STIC vers les astronomes. C'est la raison pour laquelle des plateformes comme Aïda ont vu le jour et proposent un ensemble de traitements d'images (allant de la segmentation à la réduction de données) facilitant l'interaction entre astronomes et communauté STIC.

Dans le cadre collaboratif avec la communauté astronomique, le chapitre suivant présente une nouvelle méthode de segmentation markovienne floue mise à disposition de la communauté astronomique.

2 Segmentation markovienne floue

Introduction

La segmentation multibande est un processus permettant de partitionner une observation vectorielle Y composée de c bandes sous la forme d'un champ d'étiquettes X à valeurs dans un ensemble discret Ω composé de K éléments : $\Omega = \{\omega_1 \cdots \omega_K\}$ où chaque ω_i est une classe. L'utilisation d'une telle carte obtenue à partir d'une observation facilite le processus d'interprétation en mettant en valeur des zones d'intérêts (*i.e.*, les classes ω_i) présentes dans l'image originale. L'acquisition d'une image astronomique s'accompagne généralement d'un ensemble d'artefacts et bruits liés à l'atmosphère, aux capteurs, au système optique du télescope, etc..., qui dégradent l'image de l'objet étudié. En prenant en compte ce bruit, la segmentation permet également d'obtenir une version débruitée des observations. Il existe de nombreuses méthodes de segmentation utilisant des notions très différentes : méthodes de coalescence, d'apprentissages, basées sur la morphologie mathématique ou l'intelligence artificielle, etc... Ces méthodes montrent leurs limites en terme de prise en compte du bruit et par le fait qu'elles effectuent la segmentation bien souvent de manière supervisée (par un processus d'apprentissage sur des données déjà classées par exemple).

La segmentation par champs de Markov et/ou chaînes, basée sur l'inférence bayésienne avec l'hypothèse de markoviannité du champ des étiquettes[47, 30], introduit des liens spatiaux correspondant à une information *a priori* ainsi que des liens multibandes au travers d'un terme de vraisemblance entre l'observation et la carte de segmentation. Ainsi, par exemple, on considère *a priori* que deux pixels voisins ont une probabilité forte de partager le même comportement spectral. Cette segmentation s'accompagne en outre d'une estimation complètement automatique des paramètres du modèle (généralement nombreux), notamment par une estimation de la statistique du bruit. Dans de telles méthodes, la distribution de la luminosité au sein d'une classe est supposée gaussienne mais le modèle permet également de prendre en compte d'autres types de lois dont, notamment, la loi gaussienne généralisée ou la loi log-normale, ainsi que des lois gaussiennes multidimensionnelles dans le cas où l'observation est multibande (vecteur de luminosité en chaque pixel). Dans la suite de ce document, nous utiliserons le terme *bruit* pour désigner un bruit de classes, statistique.

Les observations sont généralement segmentées en plusieurs classes dures, c'est à dire que chaque pixel appartient à une classe homogène (*i.e.* zone de l'image dont : *étoile* ou *fond* par exemple). Dans une observation astronomique, les objets étudiés sont généralement diffus et leurs frontières ne sont pas clairement définies. L'approche floue peut alors être utilisée dans le cas d'observation portant sur un objet de type nuage de gaz,

de poussières... En effet, la séparation entre un nuage de gaz et le fond se fait de manière graduelle par une décroissance en luminosité. Il est alors difficile d'attribuer une classe dure aux pixels proches de la zone "nuage". Les approches markoviennes floues[60, 63] peuvent apporter une solution originale à ce dilemme en modélisant le fait qu'un pixel puisse appartenir à plusieurs classes (simultanément 2 dans ce document) avec un certain degré d'appartenance à l'une et l'autre, ce degré étant représenté par une classe floue. Le flou permet ainsi de modéliser l'imprécision, c'est à dire le fait qu'il n'est pas possible de connaître avec précision l'étiquette associée à un pixel tandis que la probabilité modélise l'incertitude au travers le calcul d'un terme de vraisemblance renseignant sur la probabilité d'appartenance d'un pixel à chacune des classes en fonction de la luminance multibande observée. Les modèles markoviens durs et flous sont généralisables au cas multibande en utilisant des lois statistiques multidimensionnelles. Cependant cette généralisation n'est pas toujours possible, notamment dans le cas non-gaussien où l'expression analytique multidimensionnelle des lois est inconnue. Dans le cadre multibande gaussien, l'approche markovienne apporte réellement une aide à l'interprétation des données multibandes. En effet, chaque objet présente généralement une variation comportementale en fonction de la longueur d'onde étudiée, conséquence directe de sa composition chimique et de son activité thermodynamique. La prise en compte mutuelle, par l'astronome, de l'information apportée par chaque bande peut se révéler difficile. Par exemple, dans le cas d'une observation dans laquelle chaque bande révèle un comportement différent, la confrontation entre les différentes bandes peut se révéler délicate. La segmentation markovienne réalise alors un résumé de cette information multispectrale sous la forme d'une carte simple dans laquelle les pixels de comportements spectraux identiques appartiendront à la même classe. Dans toute méthode de segmentation, un nombre de classes K doit être fixé ou estimé *a priori*. Ce nombre K reflète la connaissance que l'on a de l'observation et dépend fortement du nombre et du type des objets étudiés. Dans le cas d'images astronomiques, ce nombre est généralement fixé par l'utilisateur en fonction de la nature des objets présents ou attendus dans l'image et/ou du type d'étude à mener. La première partie de ce chapitre présente un état de l'art des principales méthodes de segmentation. Puis, dans une deuxième partie, les modèles markoviens et plus particulièrement les champs de Markov flous[62] sont présentés et étudiés. Enfin, une troisième partie présente des résultats de segmentation markovienne floue par champs de Markov sur des images simulées puis sur des images astronomiques multibandes.

2.1 Notations utilisées

Notation	Signification
X	Champ des étiquettes
Y	Champ des observations
Ω	Ensemble des classes
K	Nombre de classes $\rightarrow Card(\Omega)$
ω_k	Classe k
S	Ensemble des sites de X ou Y
s	Site
x_s	Étiquette au site s
N	Nombre de site dans l'image $\rightarrow Card(S)$
V_s	8-voisinage du site x_s
ϵ_s^k	Degré d'appartenance du site s à la classe k
$U_f(x)$	Énergie floue
Z	Constante de normalisation
C_i	Ensemble des cliques d'ordre i
Φ_i	Fonction de cliques d'ordre i
c	Nombre de bandes d'une image multibande
\mathbf{l}_s	Vecteur des luminances au site s
Γ_k	Matrice de variance-covariance de la classe k
$y_{k,s}^{(i)}$	Luminance au site s avec la classe k sur la bande i
$f_k(\mathbf{l}_s)$	Densité de probabilité d'avoir l'étiquette k avec le vecteur luminance \mathbf{l}_s
$\ln(f_k(\mathbf{l}_s))$	Terme d'attache aux données avec le vecteur luminance \mathbf{l}_s et l'étiquette k
η_{ω_k}	Potentiel de cliques singletons pour la classe ω_k
ν	Potentiel de cliques singletons pour les classes floues
β	Potentiel de cliques dures du second ordre
β^f	Potentiel de cliques floues du second ordre
$\phi(x_s, x_t)$	Fonction d'énergie floue pour le calcul de $U_f(x)$
ι	Exposant paramétrable de la fonction $\phi(x_s, x_t)$
n	Nombre de classes floues
$U_2(x, y)$	Terme d'attache aux données
μ_k	Moyenne de la classe k
σ_k	Ecart Type de la classe k
β^c	Vecteur des paramètres de la loi a priori
$U'(x)$	Gradient de la méthode d'estimation stochastique de Younés

2.2 Les méthodes de segmentation

Les méthodes de segmentation peuvent se diviser en deux grandes catégories :

- les méthodes supervisées où les paramètres du modèle sont fournis ou obtenus grâce à une étape d'apprentissage ;
- les méthodes non-supervisées pour lesquelles les paramètres du modèle sont estimés automatiquement dans le cas de méthodes paramétriques.

2.2.1 Méthodes supervisées

Les méthodes supervisées consistent à déterminer des frontières de décision linéaires ou non-linéaires afin de segmenter les données. Les méthodes de segmentation linéaires ne sont généralement pas applicables à des données non linéairement séparables, puisque les frontières de décision linéaires obtenues par ces méthodes ne prennent pas correctement en compte la répartition souvent complexe des données.

Méthodes de segmentation linéaires

L'analyse factorielle discriminante[74], par exemple, sépare linéairement les données en les projetant dans un espace minimisant la variance intra-classes tout en maximisant la variance inter-classes. Cette méthode est particulièrement rapide et les frontières de décisions obtenues discriminent linéairement les nuages de points. L'inconvénient majeur de cette méthode est la nécessité de disposer d'un ensemble d'apprentissage complet et pertinent afin de déterminer les frontières de décision entre les classes. La généralisation de la classification obtenue à des données non classifiées est, en outre, généralement difficile.

Les réseaux de neurones (sans couches cachées), issus de l'intelligence artificielle, permettent de classifier des données de manière linéaire. Un réseau de neurones est composé d'une couche de neurones d'entrée ainsi que d'une couche de neurones de sortie. On peut également intercaler un ensemble de couches intermédiaires (couches cachées) entre les couches d'entrée et de sortie pour obtenir un réseau plus ou moins complexe. Chaque neurone sur la couche l est connecté à un ou plusieurs neurones de la couche supérieure $l + 1$ (sauf pour les neurones appartenant à la couche de sortie). Les poids de chacune des connexions sont obtenus lors de l'étape d'apprentissage du réseau à l'aide généralement de l'algorithme de rétropropagation du gradient. Le réseau apprend alors à réagir en fonction de son entrée et de la valeur de sortie attendue. Après apprentissage, les données qui n'ont pas servies pour l'apprentissage sont alors présentées au réseau. Le perceptron[55] est un réseau de neurones basique ne comportant aucune couche intermédiaire et classifiant les données de manière linéaire.

La discrimination linéaire reste toujours inadaptée dans le cas de distributions de données complexes. C'est la raison pour laquelle de nombreuses méthodes non-linéaires ont été développées afin d'apporter une solution à ce problème.

Méthodes de classification non-linéaires

Le perceptron multicouches[66], un réseau de neurones possédant une ou plusieurs couches cachées, permet d'obtenir des frontières de décision beaucoup plus complexes et non-linéaires. Cependant, tout comme le perceptron basique, ces méthodes neuronales nécessitent un apprentissage préalable sur des données tests et se heurtent rapidement aux problèmes de sur/sous-apprentissage et de capacités de généralisation dégradées.

La méthode des *Support Vector Machine* (SVM)[16] est une approche non-linéaire élégante. En effet, les SVM utilisent un noyau (simple fonction analytique), ou une combinaison de noyaux simples, afin de linéariser les données et obtenir un hyperplan séparant les classes. La méthode SVM est rapide et souple d'utilisation notamment grâce à la construction de noyaux particuliers et spécifiques à une problématique donnée mais reste supervisée.

Par ailleurs, les algorithmes génétiques[32, 5] sont une méthode d'optimisation possible se calquant sur la théorie de l'évolution biologique. Ces algorithmes peuvent explorer un très grand espace de solutions et trouver une solution minimisant une fonction d'erreur (fonction d'adaptation) par une série de croisements, de mutations des individus constituant la population. Les individus minimisant la fonction d'adaptation sont conservés tandis que ceux ne s'adaptant pas au problème sont éliminés lors d'une étape de sélection. Le choix de la fonction d'adaptation permet une généralité totale dans l'utilisation de ces algorithmes évolutionnaires mais les algorithmes génétiques ont l'inconvénient d'être lents et leur utilisation nécessite une calibration correcte de leurs nombreux paramètres.

2.2.2 Méthodes non-supervisées

Les méthodes non-supervisées sont très intéressantes car elles ne supposent pas d'étapes d'apprentissage ou la mise à disposition d'un ensemble de données préalablement étiquetées. De plus elles ne se heurtent pas au problème de généralisation et/ou de pertinence de l'ensemble d'apprentissage. Cependant leur utilisation est souvent délicate et spécifique à un type de traitement.

Méthodes de coalescence

Les méthodes de coalescence sont nombreuses et très souvent utilisées pour leur facilité et leur rapidité en temps de calcul. La méthode des K-Moyennes[21] est par exemple, une méthode basée sur un regroupement (*clustering*) de points en fonction d'une métrique d préalablement définie (distance euclidienne, distance de Bhattacharya, distance $L1...$). L'observation est découpée en plusieurs groupes tels que les éléments d'un même groupe soient les plus proches possibles et ceux de groupes différents soient les plus différents possibles au sens de la métrique d . La méthode des K-Moyennes n'introduit aucune contrainte spatiale entre l'élément courant et ses voisins dans l'image et est basée uniquement sur le choix de la métrique d .

L'algorithme LBG (Linde-Buzo-Gray)[78] consiste à "découper" successivement l'observation à l'aide de l'algorithme des K-moyennes (avec la métrique d). La principale différence avec la méthode précédente réside dans la construction des regroupements dans l'image. En effet, le nombre de classes croît progressivement dans l'algorithme des LBG (*via* une suite de découpage des regroupements déjà établis) alors qu'il est fixé pour les K-moyennes. Comme pour les K-moyennes, l'algorithme LBG n'introduit aucune contrainte spatiale entre l'élément courant et ses voisins dans l'image.

Méthodes d'estimation de densité de probabilité

Une autre famille de méthodes non-supervisées se propose d'estimer de manière paramétrique ou non les densités de probabilité des données afin d'effectuer une classification. La méthode EM[10] (Expectation-Maximization) permet, par exemple, d'estimer les paramètres de la densité de probabilité des données de manière paramétrique au sens du maximum de vraisemblance. D'une manière plus générale, l'algorithme EM se propose d'augmenter les observations avec des variables cachées X au lieu d'utiliser seulement les observations Y afin d'effectuer une série de maximisations simples plutôt qu'une maximisation complexe dans le cas où les seules observations sont utilisées. Les observations Y

sont donc considérées comme des données incomplètes. L'ajout des données manquantes X permet alors d'aboutir aux données complètes (X, Y) . Les variables X contiennent des informations pertinentes pour estimer les paramètres θ et les paramètres θ permettent d'estimer les variables X . Ceci permet alors d'utiliser une stratégie consistant à déterminer X à partir d'une estimée initiale de θ puis à ré-estimer θ en prenant en compte Y et les variables évaluées X . Ce processus est itéré jusqu'à la convergence des estimés[39].

Les méthodes d'estimation de densité non-paramétrique découlent de la formule générale de l'estimation d'une densité de probabilité $f(x)$ non-paramétrique :

$$\hat{f}(x) = \frac{k}{N.V_x} \quad (2.1)$$

où x est un point de la distribution, V_x le volume autour de x , N le cardinal de la distribution et k le nombre de points de la distribution appartenant à V_x . Les méthodes de type k -plus proches voisins[21] permettent de déterminer V en fixant k mais ces méthodes sont peu robustes au bruit. *A contrario*, les méthodes d'estimation de densité par noyau nécessitent de fixer V et de déterminer k à partir des données. La méthode des noyaux de Parzen[17] se propose, par exemple, d'estimer la densité de probabilité $\hat{f}(x)$ en utilisant une fonction particulière appelée noyau. De nombreux noyaux peuvent être utilisés[17] (gaussien, Epanechnikov,...) mais nécessitent la définition d'un paramètre (correspondant au volume V_x) qui est généralement fixé empiriquement.

Méthodes basées sur l'inférence bayésienne

Les méthodes dérivant de l'inférence bayésienne[29] consistent à estimer une réalisation x (la carte de segmentation) d'une variable aléatoire X en fonction de l'observation Y en modélisant la probabilité conjointe $P(X = x, Y = y)$. Une fonction de coût est alors introduite mesurant l'erreur entre x et son estimation \hat{x} . Plusieurs estimateurs se dérivent du choix de la fonction de coût, par exemple, l'estimateur du *Maximum A Posteriori* ou des *Modes des Marginales a Posteriori*. Ces deux estimateurs ainsi que les éléments de base de l'inférence bayésienne sont présentés dans la partie suivante. Il existe de nombreux estimateurs comme le critère du Minimax[8] qui ne suppose aucune connaissance sur les distributions *a priori* (*i.e.*, $P(X = x)$) ainsi que le critère de Neyman-Pearson[22] qui ne nécessite également aucune connaissance sur les distributions *a priori* ainsi que sur les fonctions de coûts.

La théorie markovienne présentée dans la partie suivante s'appuie sur la théorie bayésienne. Elle consiste à utiliser l'hypothèse de markoviannité du champ des étiquettes afin de faciliter l'estimation de \hat{x} . Plusieurs modèles dérivent de cette hypothèse :

- les champs de Markov[62] introduisent une contrainte de voisinage spatial et permettent ainsi une régularisation spatiale du champ des étiquettes en supposant, par exemple, que deux pixels voisins ont une forte probabilité d'appartenir à la même classe. Les champs de Markov sont présentés et appliqués au cas flou dans la partie suivante ;
- les chaînes de Markov[61] consistent à parcourir l'image à l'aide d'un parcours fractal d'Hilbert-Peano, qui préserve mieux l'information de voisinage par rapport à un simple parcours ligne par ligne (ou colonne par colonne), transformant ainsi les données bidimensionnelles en une chaîne monodimensionnelle où chaque pixel est

précédé et précède un autre élément de la chaîne. L'état d'un pixel dépend alors uniquement de l'élément le précédant dans la chaîne ;

- le quadarbre markovien[15] introduit un voisinage en échelle[15]. Chaque observation est exprimée sous la forme d'une pyramide multirésolution où chaque pixel possède un père (échelle supérieure) et plusieurs fils (échelle inférieure). Le voisinage ainsi obtenu est un voisinage en échelle. La figure 2.1 présente le résultat d'une segmentation markovienne effectuée sur le quadarbre.

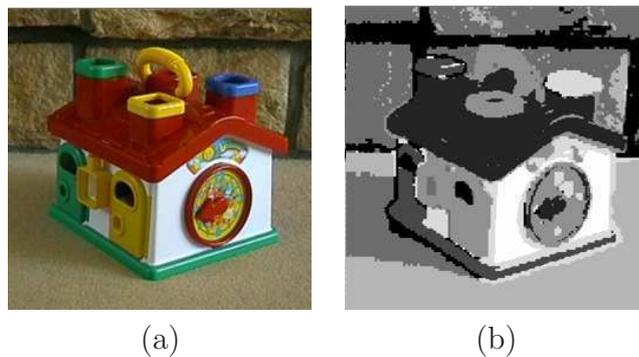


FIG. 2.1 – (a) : Image 3 bandes représentée sous la forme d'une composition colorée *RVB*. (b) : Carte de segmentation 8 classes obtenue sur le quadarbre markovien. Dans cette carte de segmentation, chaque classe correspond à des pixels de comportements spectraux similaires. Ainsi, par analogie avec la composition colorée (a), chaque pixel de couleur semblable (comportement spectral similaire sur 3 bandes) appartiendra à la même classe dans la carte de segmentation. Contrairement à l'imagerie astronomique, l'approche floue est inutile dans ce cas, où les frontières entre les zones de l'image sont clairement définies.

Autres méthodes

L'intelligence artificielle propose une série de méthodes dérivées des approches neuronales afin de classifier les données de manière non-supervisée. C'est le cas par exemple des algorithmes ART (Adaptive Resonance theory)[27] et des réseaux de Kohonen[41] permettant d'auto-organiser les connaissances en structure tendant à résoudre le problème de la stabilité-plasticité. La stabilité correspond à la capacité du système à organiser les données tandis que la plasticité correspond à la capacité du système à appréhender de nouvelles données.

Enfin la morphologie mathématique propose également des méthodes de segmentation basées sur des opérateurs dérivés des fermetures et ouvertures morphologiques[69, 28]. Ces approches ne prennent généralement pas en compte le bruit de l'image, pouvant être porteur d'information, qui est filtré dans une étape préalable à la segmentation.

2.3 Segmentation markovienne floue

Le modèle markovien flou[60, 63] se situe dans le cadre de l'estimation bayésienne. Les principaux éléments de l'estimation bayésienne sont donc rappelés dans la section

suivante.

2.3.1 Théorie de l'estimation bayésienne

L'observation est représentée par un champ de variables aléatoires $Y = (Y_s)_{1 \leq s \leq N}$ où N est le nombre de pixels (scalaires dans le cas monobande et vecteurs dans le cas d'images multibandes) de l'image. L'image segmentée (inconnue) est définie sur la même grille : $X = (X_s)_{1 \leq s \leq N}$. On cherche donc à estimer une réalisation de X à partir d'une réalisation de Y . À chaque site s de X correspond une étiquette x_s . Par analogie avec le champ des observations, un site du champ des étiquettes correspond à un pixel et son étiquette à sa valeur dans Ω . Le champ Y prend ses valeurs dans \mathbb{R}^n . Il s'agit alors de modéliser conjointement les étiquettes et les observations dans le cadre bayésien à l'aide de la probabilité jointe $P_{X,Y}(x, y)$. La loi de Bayes nous permet d'écrire :

$$P_{X,Y}(x, y) = P_{Y|X}(y|x).P_X(x) \quad (2.2)$$

La probabilité $P_{Y|X}(y|x)$ représente la probabilité d'avoir les observations connaissant les étiquettes et $P_X(x)$ introduit des connaissances sur la répartition des étiquettes dans la carte de segmentation (loi *a priori*). Toujours d'après la loi de Bayes, on peut écrire la probabilité *a posteriori* :

$$P_{X|Y}(x|y) = \frac{P_{X,Y}(x, y)}{P_Y(y)} = \frac{P_{Y|X}(y|x).P_X(x)}{P_Y(y)} \quad (2.3)$$

$P_{Y|X}(y|x)$ peut se factoriser sous la forme suivante :

$$P_{Y|X}(y|x) = \prod_s P_{Y_s|X_s}(y_s|x_s) \quad (2.4)$$

Les expressions 2.3 et 2.4 font intervenir trois termes :

- $P_{Y_s|X_s}(y_s|x_s)$: vraisemblance entre la classe affectée en un site et la luminance observée en ce même site ;
- $P_X(x)$: probabilité *a priori* ;
- $P_Y(y)$ n'est pas pris en compte dans le processus de segmentation car il ne dépend pas de x .

Il convient donc maintenant de définir des estimateurs du champ des étiquettes à partir de la connaissance de $P_{X|Y}(x|y)$. L'estimateur \hat{x} permet d'associer un champ des étiquettes estimé à la réalisation y du champ des observations. On définit alors une fonction de coût $C(x, \hat{x})$ mesurant l'erreur entre le champ des étiquettes x et son estimation \hat{x} . Cette fonction définit le risque associé à cet estimateur. La recherche de l'estimateur optimal \hat{x}_o s'effectue donc en minimisant la fonction de coût C :

$$\hat{x}_o = \operatorname{argmin}_{\hat{x}} E[C(X, \hat{x})|Y = y] = \operatorname{argmin}_{\hat{x}} \sum_{x \in \Omega} C(x, \hat{x}) P_{X|Y}(x|y) \quad (2.5)$$

Le choix de la fonction de coût est important dans la construction d'un estimateur bayésien. Deux fonctions de coût différentes ainsi que les estimateurs résultants sont présentés ici.

L'estimateur du *Maximum a Posteriori* (MAP)

La fonction de coût du critère MAP s'écrit de la manière suivante :

$$C(x, \hat{x}) = 1 - \lambda(x, \hat{x}) \quad (2.6)$$

avec

$$\lambda(x, \hat{x}) = \begin{cases} 1 & \text{si } x = \hat{x} \\ 0 & \text{sinon} \end{cases} \quad (2.7)$$

On peut alors remarquer que cette fonction de coût pénalise toutes les configurations différentes de \hat{x} de la même manière. D'après les équations 2.5, 2.6 et 2.7, on peut écrire :

$$\hat{x}_0 = \underset{x \in \Omega}{\operatorname{argmin}} \sum (1 - \lambda(x, \hat{x})) P_{X|Y}(x|y) \quad (2.8)$$

et en déduire :

$$\hat{x}_0 = \underset{x \in \Omega}{\operatorname{argmax}} P_{X|Y}(x|y) \quad (2.9)$$

L'équation 2.3 permet alors d'écrire l'expression de l'estimateur du MAP :

$$\hat{x}_{map} = \underset{x \in \Omega}{\operatorname{argmax}} P_{Y|X}(y|x) \times P_X(x) \quad (2.10)$$

Cette estimateur est très utilisé mais pénalise de la même manière les différentes configurations de \hat{x} . L'estimateur du *Modes des Marginales a Posteriori* (MPM) permet d'éviter cet inconvénient.

L'estimateur du *Modes des Marginales a Posteriori* (MPM)

La fonction de coût du MPM est la suivante :

$$C(x, \hat{x}) = \sum_{s \in S} (1 - \lambda(x_s, \hat{x}_s)) \quad (2.11)$$

avec

$$\lambda(x_s, \hat{x}_s) = \begin{cases} 1 & \text{si } x_s = \hat{x}_s \\ 0 & \text{sinon} \end{cases} \quad (2.12)$$

Cette fonction est relativement similaire à celle du MAP (equation 2.6) excepté le fait qu'elle pondère l'erreur par le nombre de sites mal étiquetés. La fonction de coût du MPM introduit donc un critère local par rapport à celle du MAP. On peut alors écrire l'estimateur MPM :

$$\forall s \in S, \hat{x}_{smap} = \underset{x_s \in \Omega}{\operatorname{argmax}} P_{X_s|Y}(x_s|y) \quad (2.13)$$

Lorsque le bruit de l'observation est important, l'estimateur MPM est plus robuste que l'estimateur MAP. Cependant, la connaissance des lois marginales en chaque site conditionnellement aux observations n'est pas toujours possible. Ces lois seront alors approchées.

2.3.2 Modèle markovien flou

Le modèle markovien flou se divise en deux parties. Le premier modèle est un modèle spatial (des données “vérité-terrain”) prenant en compte le 8-voisinage de chacun des sites s et introduisant une régularisation spatiale. Le deuxième modèle est un modèle multibande (modèle des observations) qui consiste à maximiser la vraisemblance entre la luminance multibande en un site de l’observation et l’étiquette correspondante dans le champ des étiquettes. Cette maximisation est effectuée en prenant en compte le bruit de l’observation au travers du terme d’attache aux données.

2.3.2.1 Modèle spatial des données “vérité-terrain”

La stratégie bayésienne consiste à minimiser le risque d’erreur commis en segmentant l’image. Néanmoins, le nombre de réalisations possibles de X étant trop élevé pour parcourir l’espace des solutions, l’hypothèse de markoviannité du champ des étiquettes permet de “guider” la minimisation en associant une plus forte probabilité à certaines configurations de champs des étiquettes. Un champ est markovien si il vérifie la propriété suivante :

$$\forall s \in S, P[X_s = x_s | (X_t)_{t \neq s} = (x_t)_{t \neq s}] = P[X_s = x_s | X_{V_s} = (x_{s_1}, \dots, x_{s_q})] \quad (2.14)$$

où

- V_s : k -voisinage du site s ne comprenant pas s ;
- S : Ensemble des sites de X .

En chaque site s de X , la probabilité d’avoir une étiquette x_s connaissant tout le champ est la même que celle d’avoir une étiquette x_s connaissant seulement ses voisins.

La condition suivante permet d’assurer l’unicité du processus X :

$$P[X = x] > 0 \quad (2.15)$$

On peut ainsi affirmer que toutes les configurations de X ont une probabilité non nulle de se réaliser.

La forme la plus générale d’un champ de Markov est une distribution de Gibbs. Etant donné un système de voisinage V défini (4 ou 8-voisinage par exemple), le champ X est un champ de Gibbs si sa distribution s’écrit sous la forme suivante :

$$P_X(x) = \frac{1}{Z} \exp(-U(x)) \quad (2.16)$$

où $U(x)$ est une fonction d’énergie de Gibbs définie sur V et Z est une constante de normalisation.

Le modèle markovien flou présenté ici prend en compte deux classes dures. Cependant, il est possible de généraliser ce modèle à k classes dures (ayant ainsi n niveaux de flous entre chaque paire successive de classes dures) mais la complexité du nouveau modèle augmente grandement et les temps de calculs également. Dans le modèle markovien flou à deux classes dures, chaque pixel est susceptible d’appartenir aux classes dures $\{\omega_0, \omega_1\}$

ou bien aux deux classes simultanément avec un certain degré d'appartenance à chacune d'entre elles :

$$\forall s \in S, x_s = (\epsilon_s^0, \epsilon_s^1) \text{ avec } \epsilon_s^0 + \epsilon_s^1 = 1 \text{ et } (\epsilon_s^0, \epsilon_s^1) \in [0, 1]^2 \quad (2.17)$$

Dans l'expression (2.17), x_s est considéré comme un vecteur à deux composantes :

- ϵ_s^0 : degré d'appartenance du site s à la classe 0 ;
- ϵ_s^1 : degré d'appartenance du site s à la classe 1.

L'expression (2.17) peut être simplifiée en posant $\epsilon_s = \epsilon_s^1 = 1 - \epsilon_s^0$. ϵ_s correspond donc au degré d'appartenance du site s à la classe 1. Soit :

$$x_s = \epsilon_s \in [0, 1], \begin{cases} \epsilon_s = 0 \text{ si le pixel appartient à la classe } \omega_0 \\ \epsilon_s = 1 \text{ si le pixel appartient à la classe } \omega_1 \\ \epsilon_s \in]0, 1[\text{ si le pixel est flou} \end{cases} \quad (2.18)$$

Le champ X prend donc ses valeurs dans l'ensemble $\Omega_f^N = [0, 1]^N$. La loi *a priori* (loi de probabilité de X_s) est donnée par une densité h relativement à la mesure $\nu = \delta_0 + \delta_1 + \mu$ avec des composantes dures (δ_0 et δ_1) et une composante floue (μ) :

$$P_{X_s}[X_s = \omega_0] = h(0) \quad (2.19)$$

$$P_{X_s}[X_s = \omega_1] = h(1) \quad (2.20)$$

$$P_{X_s}[X_s \in [a, b]] = \int_a^b h(t) dt \text{ avec } 0 < a \leq b < 1 \quad (2.21)$$

On peut alors définir la loi du champ aléatoire X en considérant la densité h_f . La probabilité de $X = x$ s'exprime à l'aide du théorème de Hammersley-Clifford établissant un lien entre champs de Gibbs et champs de Markov en introduisant le terme d'énergie de Gibbs $U_f(x)$ (équation 2.16) :

$$P[X = x = \{x_s\}_{s \in S} \text{ où } x_s \in [0, 1]] = \int_{[0, 1]^N} \frac{1}{Z} \cdot \exp^{-U_f(x)} d\nu^N \quad (2.22)$$

où Z une constante de normalisation. Il convient donc de maximiser la probabilité *a priori* (eq. 2.22).

Le terme d'énergie $U_f(x)$ peut dépendre uniquement du 8-voisinage (figure 2.2) de chacun des sites x_s . Ce terme représente un *a priori* sur les données de manière à favoriser (*resp.* défavoriser) la juxtaposition de deux pixels de classes identiques (*resp.* différentes). Par exemple, ce terme d'énergie défavorise fortement la juxtaposition directe de deux classes dures différentes mais, au contraire, favorise un gradient de classes floues pour le passage entre ces deux classes dures. Cette énergie est donc définie sur les cliques d'ordre 1 (figure 2.4) et 2 (figure 2.3). Une clique est un sous-ensemble c vérifiant les deux propriétés suivantes :

- c est un singleton ;
- tous les éléments de c sont k -voisins ($k = 4$ ou $k = 8$ selon le système de voisinage généralement défini).

L'utilisation des cliques du premier ordre en plus des cliques du second ordre permet un meilleur contrôle sur l'homogénéisation des classes floues.

x_8	x_1	x_2
x_7	x_s	x_3
x_6	x_5	x_4

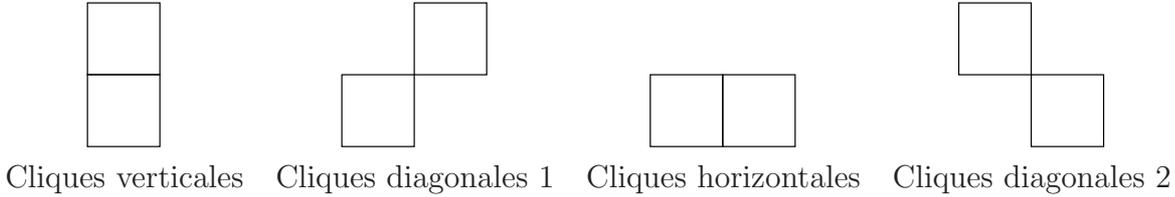
FIG. 2.2 – Système de 8-voisinage autour du site courant s 

FIG. 2.3 – Cliques du second degré

Le terme d'énergie floue peut s'écrire de la manière suivante :

$$U_f(x) = \sum_i \sum_{x_s \in C_i} \Phi_i(x_s) \text{ avec } x_s \in [0, 1]^i \quad (2.23)$$

où C_i est l'ensemble des cliques d'ordre i et $\Phi_i(x_s)$ une fonction définie sur les cliques d'ordre i . Maximiser la probabilité *a priori* (equation 2.22) revient donc à minimiser la fonction $U_f(x)$.

L'énergie floue $U_f(x)$ est définie sur tout le champ X . On introduit donc W_f comme étant la restriction de $U_f(x)$ au voisinage x_{V_s} de x_s :

$$W_f(x_s, x_{V_s}) = \sum_{V_s} U_f(x_s) \quad (2.24)$$

La fonction de cliques singletons peut s'exprimer sous la forme suivante :

$$\Phi_1(x_s) = \begin{cases} -\eta_0 & \text{si } x_s = 0 \\ -\eta_1 & \text{si } x_s = 1 \\ -\nu & \text{si } x_s \in]0, 1[\end{cases} \quad (2.25)$$

On associe ainsi un potentiel de clique (poids) pour chaque clique singleton (dure ou floue) : η_{ω_k} pour les cliques singletons dures (classe ω_k) et ν pour les cliques singletons flous. Les paramètres η_0 et η_1 contrôlent donc la proportion des classes 0 et 1 dans la carte de segmentation tandis que ν contrôle celle des classes floues. Par exemple, si η_0 est très grand, on va minimiser l'énergie (equation 2.23) lorsque le nombre de pixel de classe 0 sera grand, le raisonnement étant le même pour la classe 1 et les classes floues.



FIG. 2.4 – Clique singleton

La fonction de cliques de second degré $\Phi_2(x_s, x_t)$, $x_t \in V_s$ doit tenir compte de l'adjacence de deux pixels de classes proches ou au contraire de classes éloignées et pénaliser ces configurations en conséquence. On associe donc deux potentiels à chaque clique d'ordre 2 (figure 2.3) en fonction de la valeur de x_t (dure ou floue) :

Cliques	Potentiel dur	Potentiel flou
Cliques verticales	β_1	β_1^f
Cliques diagonales 1	β_2	β_2^f
Cliques horizontales	β_3	β_3^f
Cliques diagonales 2	β_4	β_4^f

FIG. 2.5 – Potentiels associés aux cliques d'ordre 2

Dans notre modèle markovien flou, nous avons choisi des potentiels identiques pour chaque classe. Il est cependant possible d'utiliser des potentiels durs et flous différents pour chaque classe, le nombre de potentiels à estimer devient alors grand (8 pour les deux classes dures et $n \times 4$ pour n niveaux de flous). On note, par la suite, β (*resp.* β^f) l'ensemble des potentiels durs $\{\beta_i\}_{i \in [1,4]}$ (*resp.* flous $\{\beta_i^f\}_{i \in [1,4]}$) dans les 4 directions. Selon la direction de l'adjacence de deux pixels voisins (horizontale, diagonale, verticale), on choisit alors le potentiel de clique β_i ou β_i^f correspondant.

- si les deux pixels x_s et x_t sont durs :

$$\Phi_2(x_s, x_t) = \begin{cases} -\beta & \text{si } x_s = x_t \\ \beta & \text{si } x_s \neq x_t \end{cases} \quad (2.26)$$

- si au moins un des deux pixels est flous :

$$\Phi_2(x_s, x_t) = -\beta^f \cdot \phi(x_s, x_t), \text{ avec } 0 \leq \phi(x_s, x_t) \leq 1 \quad (2.27)$$

avec

$$\phi(x_s, x_t) = 1 - 2 \cdot |x_s - x_t|^\iota \quad (2.28)$$

La fonction ϕ utilisée dans notre modèle est une fonction usuellement utilisée dans la segmentation markovienne floue. Elle permet d'obtenir une homogénéité ainsi qu'une répartition correcte des classes floues (en dégradé entre les classes dures). Cette fonction ϕ doit être choisie de la façon suivante :

- $x_s = x_t \rightarrow \phi(x_s, x_t) = 1$ et donc $\Phi(x_s, x_t) \rightarrow -\beta^f$;
- plus un pixel flou est proche de la région 0, moins il est probable qu'il soit adjacent à un pixel de la région 1 : $x_s = 1$ et $x_t \rightarrow 0 \Rightarrow \phi(x_s, x_t) \rightarrow -1$ et donc $\Phi(x_s, x_t) \rightarrow \beta^f$;
- plus un pixel flou est proche de la région 1, moins il est probable qu'il soit adjacent à un pixel de la région 0 : $x_s = 0$ et $x_t \rightarrow 1 \Rightarrow \phi(x_s, x_t) \rightarrow -1$ et donc $\Phi(x_s, x_t) \rightarrow \beta^f$;
- l'exposant ι permet d'influencer le dégradé des classes floues. Plus ι est grand, moins le dégradé des classes floues sera homogène.

Le choix de l'expression de ϕ respecte bien le principe de minimisation de $U_f(x)$ et donc de maximisation de la loi *a priori*.

Onze paramètres sont donc nécessaires pour calculer l'énergie $U_f(x)$:

- η_0, η_1 et ν : ce sont les paramètres des cliques singletons ;
- β_i avec $i \in \{1, 2, 3, 4\}$: ce sont les paramètres des cliques du second ordre dans le cas dur ;
- β_i^f avec $i \in \{1, 2, 3, 4\}$: ce sont les paramètres des cliques du second ordre dans le cas flou.

La densité de P_{X_s} conditionnellement à $X_{V_s} = x_{V_s}$ par rapport à la mesure ν est donc :

$$h^{x_{V_s}}(x_s) = \frac{\exp^{-W_f(x_s, x_t)}}{\int_0^1 \exp^{-W_f(x_s, x_t)} d\nu(t)} = \frac{\exp^{-W_f(x_s, x_t)}}{\exp^{-W_f(0, x_t)} + \exp^{-W_f(1, x_t)} + \int_{0_+}^{1_-} \exp^{-W_f(x_s, x_t)} d\nu(t)} \quad (2.29)$$

La composante continue de l'expression (2.29) (donc l'intégrale) peut se discrétiser en utilisant une somme de Riemman, on peut alors écrire :

$$\int_{a_i}^{a_{i+1}} \exp^{-W_f(x_s, x_t)} d\nu(t) \simeq \frac{1}{n} \cdot h(a_i) \text{ avec } a_0 = 0, a_1 = \frac{1}{n}, \dots, a_{n-1} = \frac{n-1}{n}, a_n = 1 \quad (2.30)$$

On peut alors expliciter la densité $h^{x_{V_s}}$ pour chaque classe dure et pour chaque classe floue :

$$h^{x_{V_s}}(0) = \frac{\exp^{-W_f(0, x_t)}}{\exp^{-W_f(0, x_t)} + \exp^{-W_f(1, x_t)} + \sum_{p=1}^{n-1} \frac{1}{n} \cdot \exp^{-W_f(a_i, x_t)}} \quad (2.31)$$

$$h^{x_{V_s}}(1) = \frac{\exp^{-W_f(1, x_t)}}{\exp^{-W_f(0, x_t)} + \exp^{-W_f(1, x_t)} + \sum_{p=1}^{n-1} \frac{1}{n} \cdot \exp^{-W_f(a_i, x_t)}} \quad (2.32)$$

$$h^{x_{V_s}}(a_i) = \frac{\frac{1}{n} \cdot \exp^{-W_f(a_i, x_t)}}{\exp^{-W_f(0, x_t)} + \exp^{-W_f(1, x_t)} + \sum_{p=1}^{n-1} \frac{1}{n} \cdot \exp^{-W_f(a_i, x_t)}} \quad (2.33)$$

Ces trois équations permettent de calculer la probabilité conditionnelle *a priori* en chaque site s . Il est alors possible de simuler des champs de Markov flous *a priori*.

2.3.2.2 Simulation de champs de Markov flous

A l'aide de l'expression de la loi *a priori* ainsi que celle de l'énergie W_f , il est possible de simuler des champs de Markov flous en utilisant l'algorithme de l'échantillonneur de Gibbs flou présenté en fin de chapitre. Les résultats de la figure 2.6 ont été obtenus à partir des paramètres du tableau 2.1.

2.3.2.3 Modèle des observations

Le modèle spatial précédemment défini permet d'introduire un *a priori* sur X et de régulariser spatialement le champ des étiquettes en fonction d'un terme d'énergie favorisant plus ou moins certaines configurations de pixels. Le modèle des observations, présenté ici, prend en compte la vraisemblance entre la carte de segmentation X et les observations Y grâce à la distribution jointe $P_{X,Y}(x, y)$.

Pour effectuer la segmentation d'une image multibande, il faut donc introduire un terme d'attache aux données mesurant la vraisemblance entre la classe affectée en un site

Images	η_0	η_1	ν	β_1	β_2	β_3	β_4	β_1^f	β_2^f	β_3^f	β_4^f	classes	ι
Image n°1	0	0	0	8	8	8	8	8.5	8.5	8.5	8.5	8	1
Image n°2	0.4	0.4	0.6	8	8	8	8	8	8	8	8	8	1
Image n°3	0.4	0.4	0.6	8	8	8	8	8	8	8	8	16	1
Image n°4	0.4	0.4	0.7	3	20	3	3	3	20	3	3	16	1
Image n°5	0.5	0.5	0.4	8	8	8	8	8	8	8	8	16	2
Image n°6	0.4	0.4	0.6	8	8	8	8	8	8	8	8	32	1

TAB. 2.1 – Paramètres pour la simulation des champs de markov flous

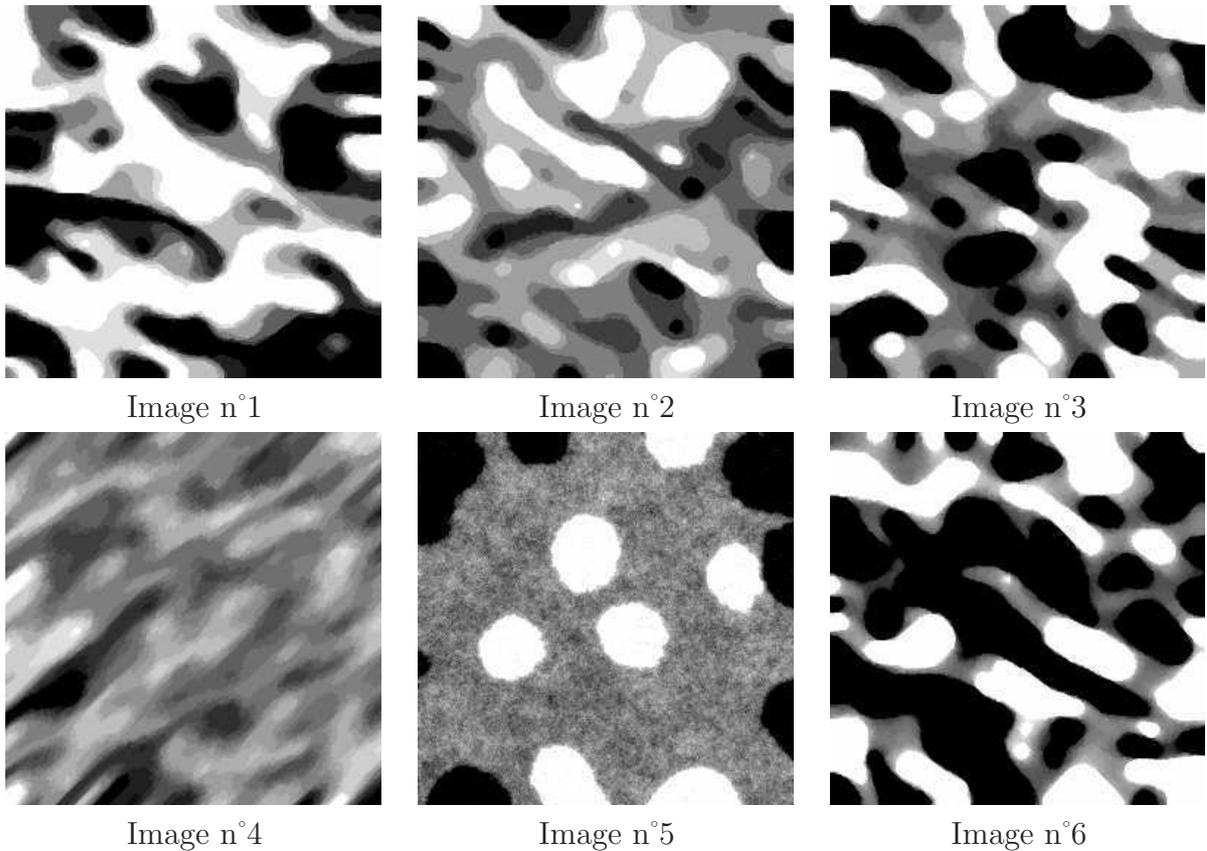


FIG. 2.6 – Résultats obtenus : échantillonneur de Gibbs flou, paramètres fournis dans le tableau (2.1), 60 itérations. On peut très bien voir en comparant l'image n°2 et l'image n°4, l'influence des paramètres de cliques singletons. Dans l'image n°2 $\nu = 0.6$ et dans l'image n°4 $\nu = 0.7$. On peut alors visuellement remarquer que le flou est présent en plus grande quantité dans l'image n°4. L'image n°1 et l'image n°2 permettent de justifier l'introduction des cliques singletons. En effet, dans l'image n°1, les valeurs des paramètres des cliques singletons sont tous nuls. On remarque alors que les classes floues sont beaucoup moins homogènes dans cette image. Il y a des transitions abruptes entre les deux classes dures. L'image n°5 est générée avec la fonction énergie (2.27) avec $\iota = 2$. On peut remarquer alors l'absence visuelle de dégradé dans l'image.

et la luminance multibande observée en ce même site. Il s'exprime de la manière suivante dans le cas multibande gaussien :

$$\ln(f_k(\mathbf{l}_s)) = \ln(2\pi^{c/2} \sqrt{\det(\mathbf{\Gamma}_k)}) + \frac{1}{2}(\mathbf{l}_s - \mu_k)^t \mathbf{\Gamma}_k^{-1} (\mathbf{l}_s - \mu_k) \quad (2.34)$$

avec :

- $\mathbf{\Gamma}_k$: matrice de variance-covariance pour la classe k (variance sur chaque bande, covariance entre bandes spectrales) ;
- \mathbf{l}_s : vecteur des luminances dans chaque bande sur un site s donné : $\mathbf{l}_s = \{Y_s^{(1)} \dots Y_s^{(b)}\}$;
- μ_k : vecteur des moyennes de chaque bande de la classe k ;
- c : nombre de bandes.

On peut donc définir un terme d'énergie globale prenant en compte l'énergie du modèle spatial et le terme d'attache aux données :

$$P(x, y) = \frac{1}{Z} \cdot \exp^{-U^f(x) - U_2(x, y)} \quad (2.35)$$

avec

$$U^f(x) = \sum_i \sum_{c \in C_i} \Phi_i(x_c) \quad (2.36)$$

et

$$U_2(x, y) = \sum_{s \in S} \ln(f_k(\mathbf{l}_s)) \quad (2.37)$$

On peut alors écrire :

$$h^{x_{V_s}, y_s}(x_s) = \frac{\exp^{-W_f(x_s, x_t) + \ln(f_k(\mathbf{l}_s))}}{\exp^{-W_f(0, x_t) + \ln(f_0(\mathbf{l}_s))} + \exp^{-W_f(1, x_t) + \ln(f_1(\mathbf{l}_s))} + \int_0^1 \exp^{-W_f(x_s, x_t) + \ln(f_t(\mathbf{l}_s))} dt} \quad (2.38)$$

En discrétisant l'intégrale $\int_0^1 \exp^{-W_f(t, x_t) + \ln(f_t(\mathbf{l}_s))} dt$, on a :

$$h^{x_{V_s}, y_s}(x_s) = \frac{\exp^{-W_f(x_s, x_t) + \ln(f_k(\mathbf{l}_s))}}{\exp^{-W_f(0, x_t) + \ln(f_0(\mathbf{l}_s))} + \exp^{-W_f(1, x_t) + \ln(f_1(\mathbf{l}_s))} + \sum_1^{n-1} \frac{1}{n} \cdot \exp^{-W_f(x_s, x_t) + \ln(f_t(\mathbf{l}_s))}} \quad (2.39)$$

Dans le cas monobande, la matrice de covariance est réduite à un scalaire σ_k^2 et on a donc avec $c = 1$

$$\ln(f_k(\mathbf{l}_s)) = \frac{(y_s - \mu_k)^2}{2\sigma_k^2} + \ln(\sqrt{2\pi}\sigma_k)$$

La définition du modèle des observations ainsi que celle du modèle "vérité-terrain" permet de proposer une segmentation multibande floue pouvant être basée sur plusieurs critères.

2.3.2.4 Segmentation multibande markovienne floue

Deux critères permettent d'effectuer une segmentation :

- le critère du MAP consistant à maximiser $P(X = x|Y = y)$ (equation 2.10) ;
- le critère du MPM consistant à maximiser $P(X_s = x_s|Y = y)$ (equation 2.13). Le MPM nécessite la connaissance (ou l'approximation) de la loi *a posteriori* en chaque site.

Il existe différents algorithmes optimisés pour la segmentation d'images car la minimisation d'une fonction est un problème complexe et il est exclu d'effectuer une prospection exhaustive :

- le recuit simulé[48] : cet algorithme s'appuie sur une descente en température ainsi que sur l'échantillonneur de Gibbs et est une solution du critère MAP. Il converge théoriquement vers le minimum global en temps infini. Sa mise en oeuvre pratique nécessite néanmoins un très grand nombre d'itérations, ce qui rend son utilisation souvent exclue ;
- l'ICM (Modes Conditionnels Itérés)[33] : cet algorithme fonctionne comme le précédent mais à la différence qu'il n'y a pas de descente en température. Celle-ci sera donc constante et égale à 1. L'ICM est une approximation du recuit simulé. Cet algorithme dépend du champ des étiquettes initial car il ne pourra visiter qu'un seul minima. Ses résultats sont excellents avec des temps de calcul bien inférieurs à ceux du recuit simulé ;
- le MPM (Mode des Marginales a Posteriori)[62] : cet algorithme utilise la loi de Monte-Carlo. Il simule un certain nombre de champs *a posteriori* en utilisant l'échantillonneur de Gibbs. L'étiquette choisie en un site s est alors celle apparaissant le plus fréquemment dans les échantillons.

La segmentation d'une observation multibande nécessite l'estimation d'un grand nombre de paramètres (pour deux classes dures et n niveaux de flous) :

- 11 paramètres de la loi *a priori* (représentant l'*a priori* que l'on a sur la solution) : 4 potentiels de cliques dures du second degré (β) , 4 potentiels de cliques flous du second degré (β^f), 2 potentiels de cliques singletons dures (η_{ω_k}) et un potentiel de cliques singletons flous (ν) ;
- 2 paramètres de la loi d'attache aux données (moyenne et variance dans le cas gaussien) pour chacune des classes dures et flous pour chaque bande ;

Les techniques d'estimation de ces deux jeux de paramètres sont présentées dans la partie suivante.

2.3.3 Estimation des paramètres du modèle markovien

Les paramètres du modèle markovien étant nombreux, il existe plusieurs types de segmentation :

- segmentation supervisée : tous les paramètres sont connus ;
- segmentation semi-supervisée : seul un des deux jeux de paramètres est connu (soit les paramètres de bruit, soit ceux du modèle *a priori*) ;
- segmentation non-supervisée : aucun paramètre n'est connu et tous doivent être estimés.

L'estimation des paramètres est une étape importante de la segmentation markovienne. En effet, les paramètres de la loi *a priori* sont nécessairement estimés à partir des champs des étiquettes obtenus à chaque itération de l'algorithme de segmentation. De plus, les paramètres du bruit sont estimés pour les classes dures (0 et 1), puis ceux des classes floues en sont déduits. Dans le cas dur de l'estimation des paramètres de la loi *a priori*, deux algorithmes peuvent être utilisés : la méthode de Derin et Elliot[20] ainsi que la méthode du gradient stochastique de Younès[79]. La première méthode est difficilement généralisable au cas multibande floue. En effet, elle nécessite de mettre à jour une table complète de toutes les configurations possibles de voisinage et est basée sur la méthode des moindres carrés : dans le cas de deux classes dures et de seize niveaux de classes floues, le nombre de configurations à mettre à jour est de 4294967552. Le gradient stochastique de Younès est donc préféré dans le cas flou. Cependant, cette méthode est très dépendante des paramètres d'initialisation.

La mise en place d'une segmentation à l'aide des méthodes du recuit simulé, ICM et MPM nécessite, en entrée, une carte de segmentation. Cette première carte est obtenue à l'aide de l'algorithme des K-moyennes (permettant d'obtenir une première estimation des paramètres du bruit de l'observation) dont le résultat alimente un classifieur basé sur le maximum de vraisemblance (maximisation du terme de l'attache aux données uniquement sans prendre en compte le terme contextuel).

2.3.3.1 Estimation des paramètres de la loi d'attache aux données

L'estimation des paramètres de la loi d'attache aux données peut se faire de plusieurs manières différentes :

Méthode du barycentre

- estimation de μ et σ pour les deux classes dures avec les moments empiriques :

$$\mu_k = \frac{1}{N_{\omega_k}} \sum_{s \in S, x_s = \omega_k} y_s \quad (2.40)$$

$$\sigma_k^2 = \frac{1}{N_{\omega_k} - 1} \sum_{s \in S, x_s = \omega_k} (y_s - \mu_k)^2 \quad (2.41)$$

où $N_{\omega_k} = \text{Card}(\{s \in S, x_s = \omega_k\})$

- déduction de μ et σ pour chaque classe floue (barycentre des paramètres du bruit des classes dures) :

$$\mu_\epsilon = (1 - \epsilon)\mu_0 + \epsilon\mu_1 \quad (2.42)$$

$$\sigma_\epsilon^2 = (1 - \epsilon)^2\sigma_0^2 + \epsilon^2\sigma_1^2 \quad (2.43)$$

Dans le cas multibande la matrice de variance covariance s'obtient de la manière suivante :

- calcul de la matrice de variance covariance pour les classes dures (entre les bandes) :

$$\Gamma_k = \begin{pmatrix} \sigma_k^2(1) & cov_{i,j} & \cdots & cov_{i,c} \\ cov_{i,j} & \sigma_k^2(2) & \cdots & \cdots \\ \vdots & \vdots & \ddots & \vdots \\ cov_{(c,j)} & \cdots & \cdots & \sigma_k^2(c) \end{pmatrix} \quad (2.44)$$

Avec :

$$cov_{i,j} = cov_{j,i} = \frac{1}{N_{\omega_k}} \sum_{s \in S, x_s = \omega_k} \bar{y}_{k,s}^{(i)} \cdot \bar{y}_{k,s}^{(j)} \quad (2.45)$$

et $\bar{y}_{k,s}^{(i)}$ la luminance centrée au site s avec la classe k sur la bande i .

- les matrices de covariance des classes floues se déduisent de celles des classes dures par la méthode du barycentre :

$$\Gamma_\epsilon = (1 - \epsilon)^2 \Gamma_0 + \epsilon^2 \Gamma_1 \quad (2.46)$$

Nous avons retenu cette méthode pour sa simplicité de mise en oeuvre et son rapide temps de calcul.

Moments empiriques

- estimation de μ et σ pour les deux classes dures avec les moments empiriques.
- estimation de μ et σ pour les classes floues avec les moments empiriques en considérant chaque classe floue comme une classe dure.

2.3.3.2 Estimation des paramètres de la loi *a priori*

Younès propose une méthode de gradient stochastique pour l'estimation des paramètres *a priori*. Cette méthode itérative consiste à calculer un gradient à 11 composantes (correspondant aux 11 paramètres *a priori*) s'exprimant comme suit :

$$U'(x) = \left[\frac{dU}{d\eta_0}, \frac{dU}{d\eta_1}, \frac{dU}{d\nu}, \frac{dU}{d\beta_1}, \dots, \frac{dU}{d\beta_4}, \frac{dU}{d\beta_1^f}, \dots, \frac{dU}{d\beta_4^f} \right] \quad (2.47)$$

On pose : $\beta^c = \{\eta_0, \eta_1, \nu, \beta_1, \beta_2, \beta_3, \beta_4, \beta_1^f, \beta_2^f, \beta_3^f, \beta_4^f\}$ l'ensemble de tous les paramètres du modèle *a priori*.

Dans le cas de cliques singletons :

$$\frac{dU}{d\eta_0} = - \sum_{s \in S} 1_{[x_s=0]} \quad (2.48)$$

$$\frac{dU}{d\eta_1} = - \sum_{s \in S} 1_{[x_s=1]} \quad (2.49)$$

$$\frac{dU}{d\nu} = - \sum_{s \in S} 1_{[x_s \in]0,1[)} \quad (2.50)$$

Dans le cas de cliques du second ordre, lorsque les deux pixels voisins x_s, x_t sont durs :

$$\frac{dU}{d\beta_k} = \sum_{s,t \in S} I(x_s, x_t) \text{ avec } I(x_s, x_t) = \begin{cases} -1 & \text{si } x_s = x_t \\ +1 & \text{si } x_s \neq x_t \end{cases} \quad (2.51)$$

Dans le cas de cliques du second ordre lorsqu'un des deux pixels au moins est flou :

$$\frac{dU}{d\beta_k^f} = \sum_{s,t \in S} g(x_s, x_t) \text{ avec } g(x_s, x_t) = -\phi(x_s, x_t) = -(1 - 2|x_s - x_t|^t) \quad (2.52)$$

La partie itérative du gradient stochastique de Younès est la suivante et est également présentée en annexe :

- étape d'initialisation : $\beta_{[0]}^c = 0$
- étape $[i + 1]$:

$$\beta_{[i+1]}^c = \beta_{[i]}^c + \frac{c_Y}{N} [U'(x_{[i+1]}) - U'(x_{[0]})]$$

Le paramètre c_Y est le coefficient de convergence. Ce nombre est en général égal à $\frac{1}{i+1}$ mais la vitesse de convergence de l'algorithme est très dépendante de c . Ce pas peut également être constant, dans ce cas, $c_Y = 1$. Selon la valeur de ce pas, le nombre d'itérations nécessaire afin d'obtenir une estimation satisfaisante peut passer de 10 à 200. Le principal inconvénient de cet algorithme est donc sa dépendance vis-à-vis de son paramètre de convergence conduisant généralement à un temps de calcul long.

2.3.3.3 Résultats de l'estimation des paramètres β^c

L'image 2.7 est générée avec des paramètres connus fournis dans le tableau 2.2. Le pas de convergence du gradient stochastique est fixé à $\frac{1}{i+1}$ où i est l'itération courante. Le tableau 2.3 présente les résultats de l'estimation des paramètres β^c et la figure 2.8 a été simulée avec les paramètres *a priori* du tableau 2.3. On peut remarquer que les estimations ne respectent pas les ordres de grandeur des paramètres initiaux. Cela vient du fait que l'application faisant correspondre un vecteur β^c à un gradient n'est pas bijective. Pour étudier le champ original et le champ simulé, il faut donc introduire des critères de comparaison, par exemple le pourcentage de flou dans les deux images ou bien une comparaison visuelle de celles-ci (orientation, regroupement des classes, homogénéité...). Cependant, le modèle markovien flou est très sensible aux paramètres β^c . Ainsi leurs estimations par l'algorithme du gradient stochastique de Younès est tributaire de cette sensibilité. Les résultats d'estimation sur des champs mixtes (classes dures et floues) sont donc faussées par cette sensibilité, l'estimation se faisant correctement uniquement sur les champs totalement durs ou flous. Les résultats présentés dans la section suivante ont donc été obtenus en mode semi-supervisé où seul l'estimation des paramètres du bruit est effectuée.

Titre	η_0	η_1	ν	β_1	β_2	β_3	β_4	β_1^f	β_2^f	β_3^f	β_4^f	Pourcentage de flou
Image n°1	-0.4	-0.4	0.8	3	3	3	3	3.5	3.5	3.5	3.5	100

TAB. 2.2 – Paramètres de simulation de champs de Gibbs

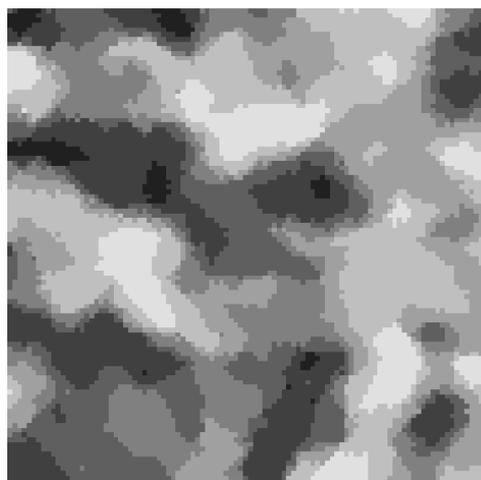


Image n°1

FIG. 2.7 – Champ de Gibbs simulé, paramètres β^c dans Tab. 2.2

Titre	$\hat{\eta}_0$	$\hat{\eta}_1$	$\hat{\nu}$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$	$\hat{\beta}_1^f$	$\hat{\beta}_2^f$	$\hat{\beta}_3^f$	$\hat{\beta}_4^f$	Pourcentage de flou
Image n°1	-0.21	-0.21	0.41	0	0	0	0	4.68	4.56	4.73	4.6	100

TAB. 2.3 – Résultats $\hat{\beta}^c$ avec Younes flou après 100 itérations sur les images (2.7)

Image n°1

FIG. 2.8 – Champ de Gibbs simulé, paramètres $\hat{\beta}^c$ dans Tab. 2.3

2.4 Résultats de segmentations

La segmentation semi-supervisée multibande consiste à estimer les moyennes et variances de chaque classe et dans chaque bande. L'image originale obtenue pour un certain jeu de paramètres β et β^f (figure (2.9)) a été bruitée avec trois paramètres différents (pour obtenir les 3 bandes - figure 2.10). Le résultat de la segmentation est présentée figure 2.11.

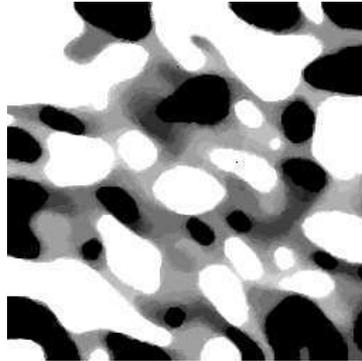


FIG. 2.9 – Image originale non bruitée

Bande	μ_0	μ_1	σ_0	σ_1	$\hat{\mu}_0$	$\hat{\mu}_1$	$\hat{\sigma}_0$	$\hat{\sigma}_1$
1	104	152	16	16	105.28	151.6	16.02	16.07
2	120	152	16	16	120.7	152	15.9	16
3	120	136	16	16	120.42	135.8	15.75	16

TAB. 2.4 – Paramètres du bruit et estimation

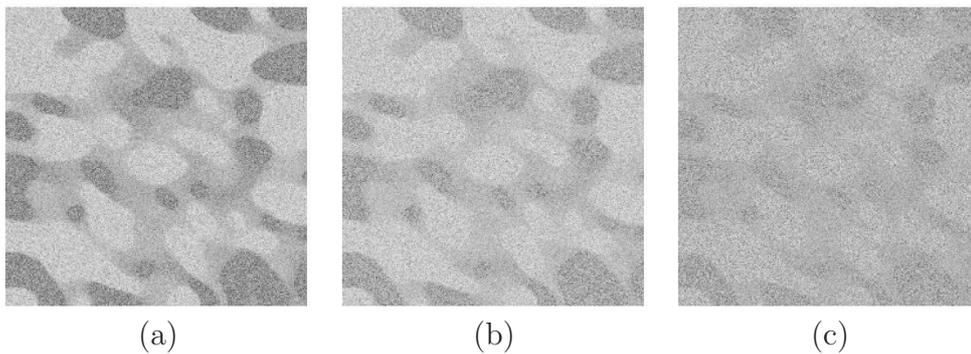


FIG. 2.10 – (a)-(c) : observation multibande : image de synthèse bruitée - paramètres du bruit dans le tableau (2.4)

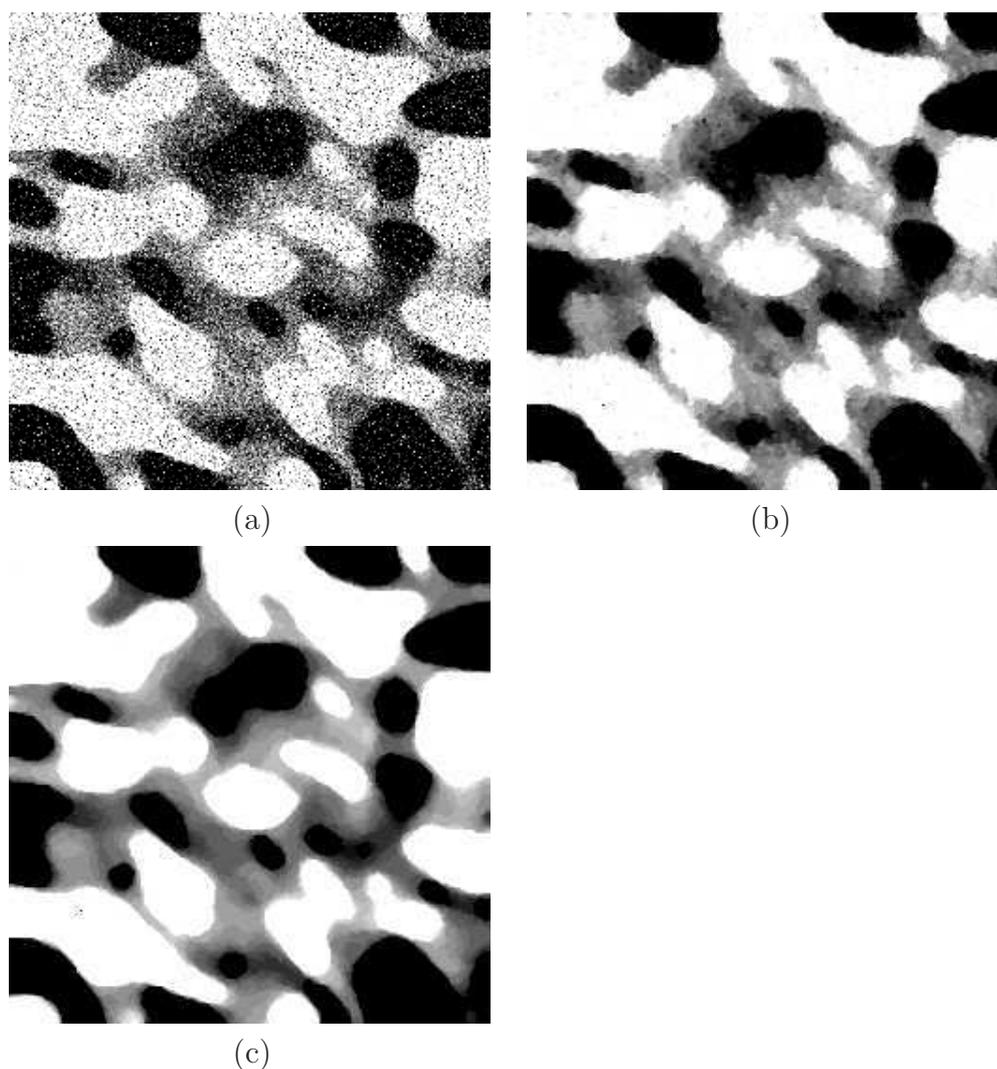


FIG. 2.11 – (a) : carte de segmentation au sens du maximum de vraisemblance. (b) : carte de segmentation à l'issue de la première itération de l'ICM. (c) : carte de segmentation finale - ICM semi-supervisé multibande - 10 itérations - 16 classes floues. La carte de segmentation obtenue en (c) est globalement similaire à l'observation originale. En effet, les zones de classes dures ont bien été retrouvées dans la carte de segmentation tandis que les zones de dégradés de classes floues sont également présentes. On peut cependant remarquer que, sur certaines zones, les dégradés de classes floues sont différents. En effet, l'estimation des paramètres du bruit des classes floues est très importante dans le processus de segmentation et une mauvaise estimation de ces paramètres peut conduire à une segmentation biaisée. La figure (a) a été obtenue en utilisant le critère du maximum de vraisemblance (MV) et donc en utilisant uniquement la loi d'attache aux données (sans *a priori* sur la distribution spatiale des classes). On peut alors remarquer, dans cette figure, que les classes floues et dures ne sont pas regroupées en zones homogènes et que le dégradé de classes floues n'apparaît pas. On peut remarquer que ces caractéristiques apparaissent dans la figure (b) et (c) où le terme d'*a priori* est pris en compte dans le modèle markovien flou.

L'image astronomique (2.12) est composée de 6 bandes et est segmentée avec 16 niveaux de flou (figure 2.13).

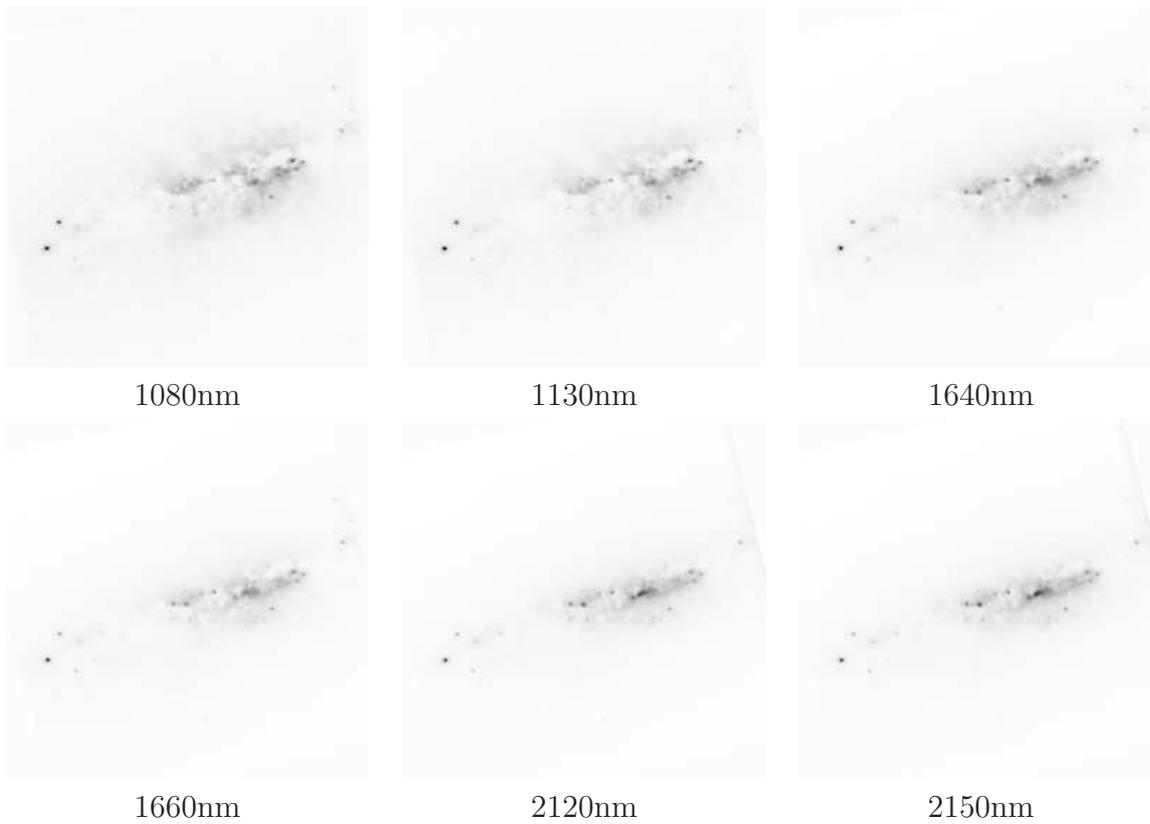


FIG. 2.12 – Galaxie M82 - 6 Bandes

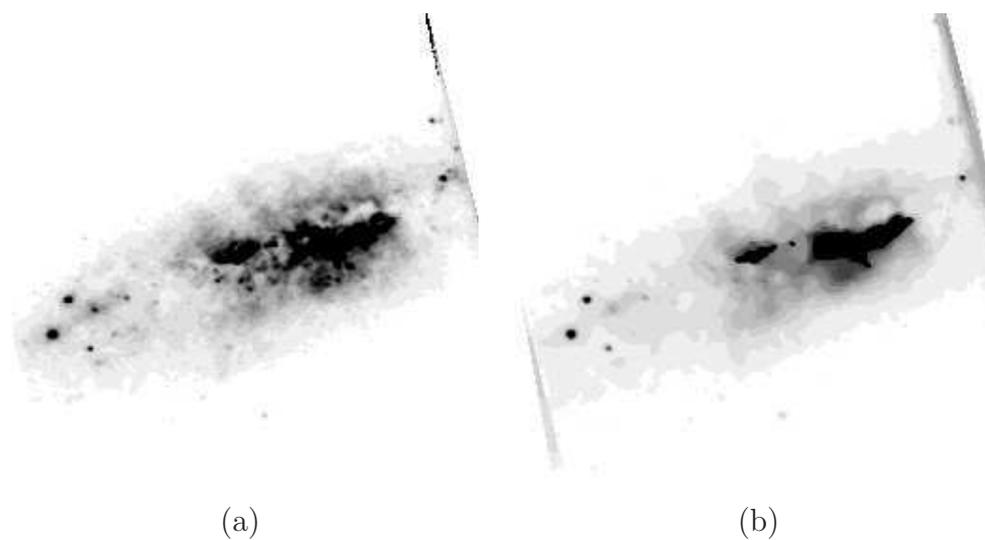


FIG. 2.13 – (a) : segmentation au sens du maximum de vraisemblance. (b) : carte de segmentation finale - ICM semi-supervisé multibande - 10 itérations - 16 Classes floues. La segmentation floue synthétise les 6 bandes originales sous la forme d'une image dont les classes sont discrètes. La zone centrale (représentée par les zones noires) et le fond sont deux classes dures. On remarque alors que, du centre de l'objet vers l'extérieur, les classes floues sont présentes dans les zones correspondant à des nuages de gaz et aux différentes zones de la galaxie.

La figure 2.14 présente une galaxie issue du catalogue Hubble Deep Field sur 6 bandes (HDF 474). Elle a été segmentée en 16 niveaux de flous avec l'algorithme ICM semi-supervisée (estimation des paramètres du bruit uniquement). La carte de segmentation est présentée figure 2.15.

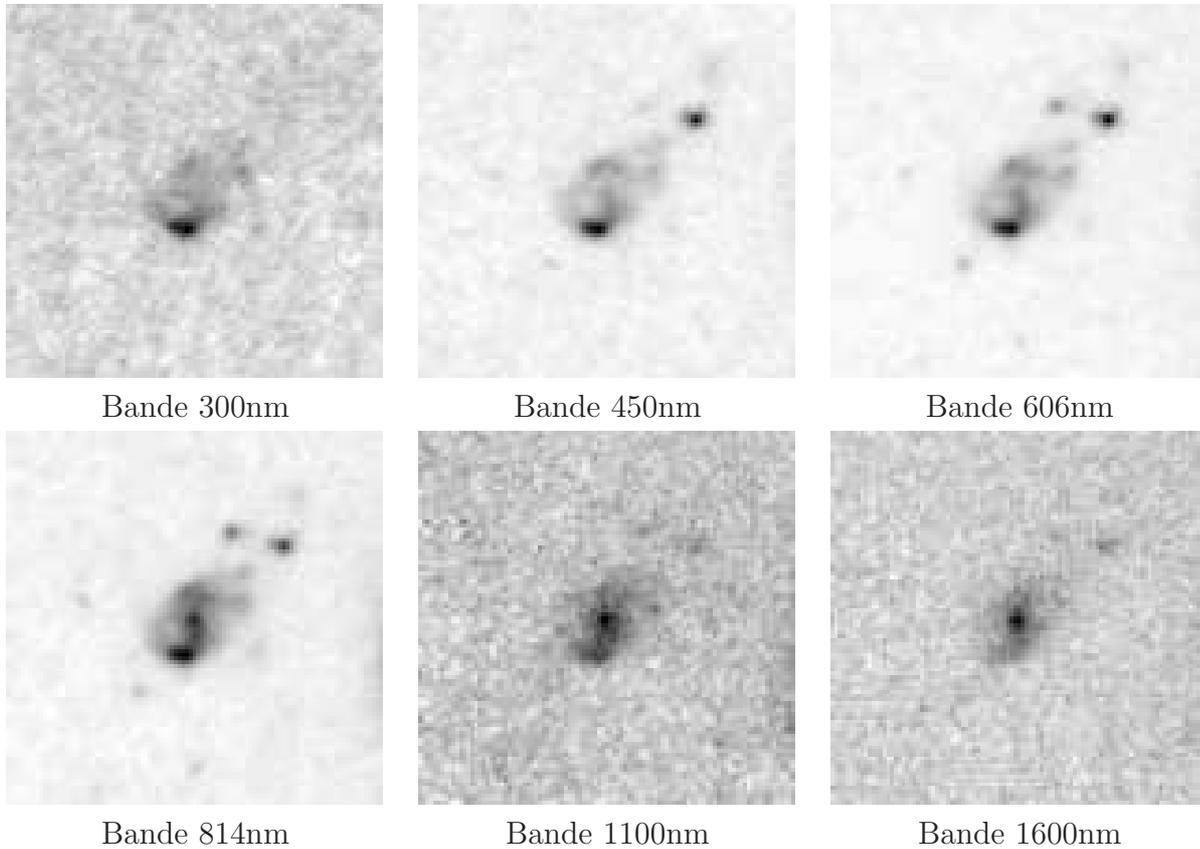


FIG. 2.14 – Galaxie de la collection d'images du Hubble Deep Field HDF-474 - 6 bandes. Taille 101×101 pixels

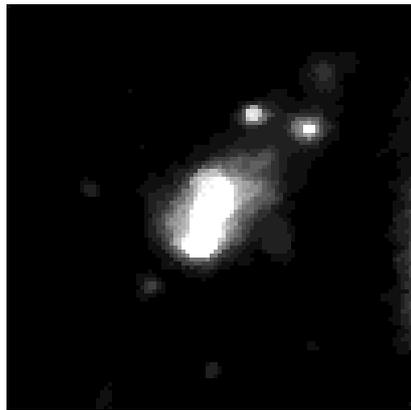


FIG. 2.15 – Carte de segmentation floue - 16 classes floues. On peut remarquer que la classe dure, en blanc, correspond au centre de la structure. On retrouve également une ébauche de forme spirale présente sur les bandes infrarouge de 814nm à 1600nm. Les classes floues obtenues se situent dans la partie supérieure de l'objet où on peut retrouver, dans les observations, une zone diffuse. Les zones de formation stellaire en haut à droite de l'image se retrouvent bien dans la carte de segmentation et sont également entourées d'un halo de classes floues correspondant à une décroissance en luminosité du centre vers l'extérieur de la galaxie.

La figure 2.16 présente une autre galaxie issue du catalogue Hubble Deep Field sur 6 bandes (HDF 550). Elle a été segmentée en 16 niveau de flous avec l'algorithme ICM semi-supervisée (estimation des paramètres du bruit uniquement). La carte de segmentation est présentée figure 2.17.

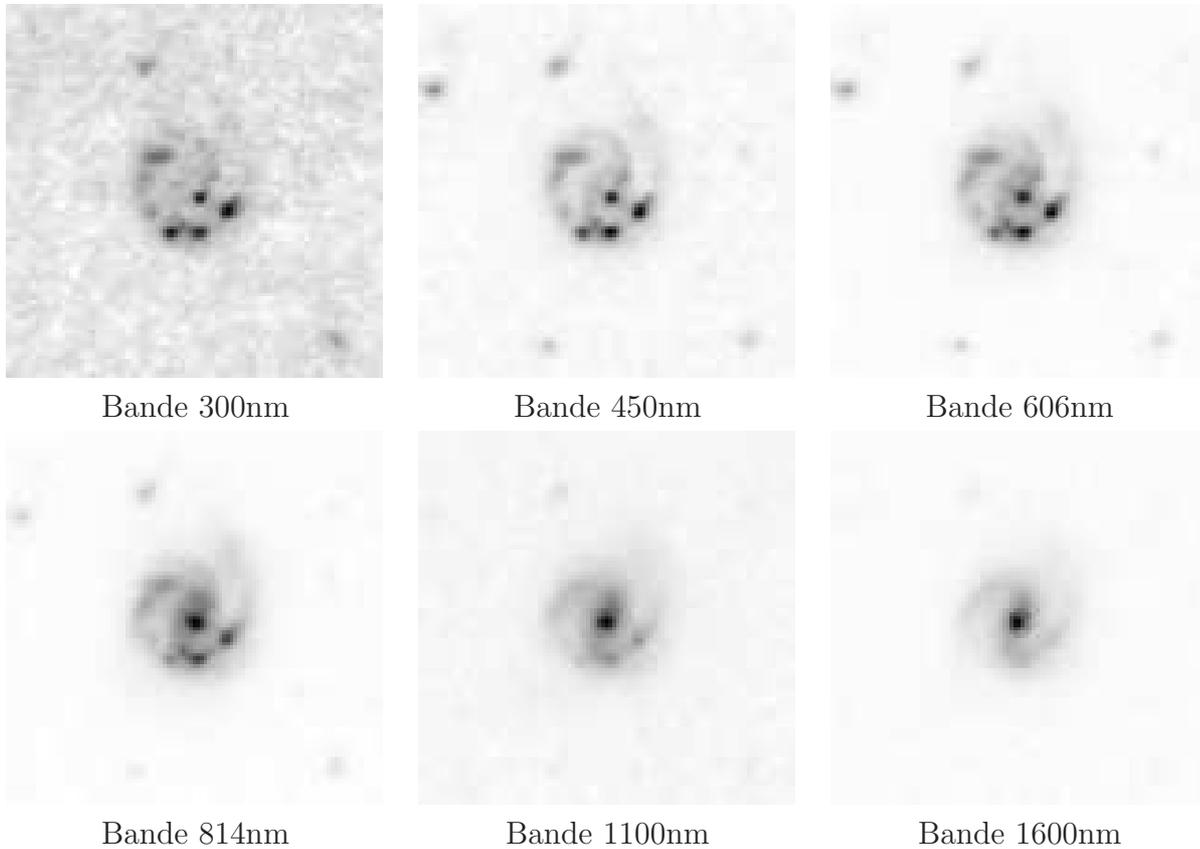


FIG. 2.16 – Galaxie de la collection d'images du Hubble Deep Field HDF-550 - 6 bandes.
Taille 101×101 pixels

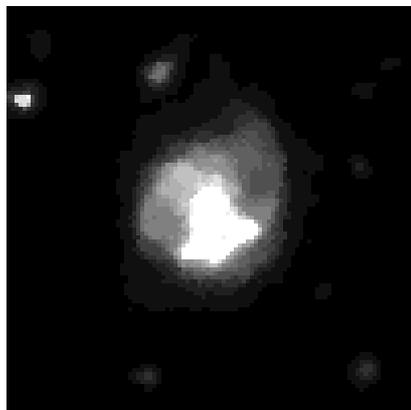


FIG. 2.17 – Carte de segmentation floue - 16 classes floues. La zone blanche englobe les zones proches du centre des étoiles les plus intenses en optique. On remarque que la forme spirale clairement apparente sur les observations n'apparaît pas dans la carte de segmentation. La classe blanche est donc dominée par la luminosité des zones de formation stellaire. Pour cette exemple, la segmentation floue n'apporte pas d'intérêt majeur.

2.5 Conclusion

La segmentation markovienne introduit une hypothèse locale simplifiant le processus de segmentation bayésienne. Ainsi, l’attribution d’une classe à un pixel de l’observation dépendra de son voisinage spatial ainsi que de la distribution de luminosité (pouvant suivre différentes lois statistiques) de sa classe d’appartenance. La généralisation des modèles markoviens au cas multibande permet d’utiliser toute l’information portée par chaque spectre dans le processus de segmentation et introduit la notion de segmentation multibande. En imagerie astronomique les frontières entre objets ne sont pas définies et les objets sont relativement diffus. Cette particularité peut justifier dans certains cas l’utilisation d’une approche floue qui permet de modéliser un degré d’appartenance aux classes dures ayant pour conséquence un modèle plus fidèle aux observations astronomiques et applicable à l’imagerie astronomique.

L’estimation des paramètres du modèle markovien se décompose en deux étapes :

- estimation des paramètres du bruit en utilisant les moments empiriques pour les classes dures, les paramètres des classes floues étant ensuite déduit de ceux-ci ;
- estimation des paramètres de la loi *a priori* en utilisant le gradient stochastique de Younés.

Le modèle markovien flou étant très sensible aux paramètres β^c (une différence d’un dixième sur chaque potentiel β_i^c peut rendre le champ *a priori* uniquement composé de classes floues ou dures), le calcul du gradient est également tributaire de cette sensibilité. Ainsi les paramètres β^c seront bien estimés dans le cas de champs uniquement flous (*resp.* durs) mais ne le seront pas correctement dans le cas de champs mixtes : l’estimation des paramètres du bruit de chaque classe sera donc faussée conduisant à une segmentation multibande floue incorrecte. Une étude poussée sur la méthode du gradient stochastique (notamment en terme de convergence et de sensibilité aux paramètres *a priori* du modèle) permettrait d’offrir une segmentation floue totalement non-supervisée. Dans [62], les cliques singletons ne sont plus prises en compte. L’estimation des paramètres *a priori* est alors robuste conduisant à une segmentation floue non-supervisée.

Les champs de Markov montrent également leur limite en terme de temps de calcul. En effet, le processus de segmentation prend, par exemple, une trentaine de minutes pour une image de taille $256 \times 256 \times 6$ pixels segmentée en 2 classes dures et 32 niveaux de flou. L’estimation des paramètres de la loi *a priori* est responsable de près de 60% de ce temps de calcul. Au contraire, l’approche par quadarbre markovien donne des résultats très satisfaisants en plus de sa rapidité. C’est la raison pour laquelle nous préférons une approche markovienne par quadarbre dans les travaux suivants dès lors qu’une carte de segmentation sera nécessaire. Cependant, nous utiliserons une approche dure car la segmentation, dans nos méthodes, est utilisée comme masque sur les observations. L’utilisation d’une approche dure simplifie donc les modèles par l’utilisation d’un nombre de classes plus restreint.

Les approches markoviennes ont montré leur robustesse face au bruit de l’observation. En effet, elles sont à même de “dégager”, dans une carte de segmentation, les objets noyés dans le bruit, là où un seuil les auraient éliminés. Détecter des objets à la limite du bruit est une problématique intéressante pour les astronomes, notamment pour le cas des objets à faible brillance de surface (galaxies LSB : *Low Surface Brightness*, par exemple). Le chapitre suivant présente une application de la segmentation markovienne monobande

pour la détection de galaxies à faible brillance de surface dans l'amas de galaxies proche Virgo.

Annexes

Echantillonneur de Gibbs flou

Le principe de cet algorithme est de maximiser :

$$\forall \omega \in \Omega, P[X = \omega | X_{V_s}] = \frac{1}{Z_s} \cdot e^{-U_f(x)}$$

avec

$$Z_s = \sum_{\omega \in \Omega} \frac{1}{Z} \cdot e^{-U_f(x)}$$

Pour cela, il faut donc calculer cette expression pour chaque classe et effectuer un tirage selon cette loi. La nouvelle étiquette tirée devra remplacer l'ancienne dans la même image (Ainsi pour le site s suivant, on utilisera la nouvelle valeur de l'étiquette précédemment calculée). Dans l'algorithme ci-dessous n'est détaillée qu'une passe de l'échantillonneur de Gibbs. Le critère d'arrêt peut être soit le nombre d'itération, soit un pourcentage minimal de pixels changeants d'une passe à l'autre.

Algorithme 2.1 Procédure Echantillonneur de Gibbs Flou

Entrée: x : Configuration Initiale
 β_c : Vecteurs des paramètres de la loi a priori
 n : Nombre de classes floues

Pour tout site s Faire

Pour tout classe dure ω_i (0 et 1) Faire

- Calculer $P[x_s = \omega_i] \leftarrow \frac{1}{Z_s} \cdot e^{-U_f(x_s)}$

Fin Pour

Pour tout classe floue ω_i Faire

- Calculer $P[x_s = \omega_i] \leftarrow \frac{1}{Z_s} \cdot \frac{1}{n} e^{-U_f(x_s)}$

Fin Pour

- Tirage de b avec $0 < b < 1$

- Tirage dans $\{0, 1, Flou\}$

Si Tirage dans flou Alors

- Trouver le plus petit j tel que $\sum_{i=1}^j P[x_s = \omega_i] > \sum_{i=1}^{Card(\Omega)} P[x_s = \omega_i]$
 ω_i étant une classe floue

Fin Si

- $x_s \leftarrow \omega_j$

Fin Pour

Gradient stochastique flou de Younès

Le principe de cet algorithme est de calculer un gradient à chaque itération :

$$U'(x) = \left[\frac{dU^f}{d\eta_0}, \frac{dU^f}{d\eta_1}, \frac{dU^f}{d\nu}, \frac{dU^f}{d\beta_1}, \dots, \frac{dU^f}{d\beta_4}, \frac{dU^f}{d\beta_1^f}, \dots, \frac{dU^f}{d\beta_4^f} \right]$$

avec

$$\frac{dU_s}{\beta_k} = \sum_{s,t \in S} I(x_s, x_t) \text{ avec } I(x_s, x_t) = \begin{cases} 0 & \text{si } x_s = x_t \\ +1 & \text{si } x_s \neq x_t \end{cases}$$

puis d'effectuer les itérations suivantes :

- étape d'initialisation : $\beta_{[0]}^c = 0$
- étape $[i + 1]$:

$$\beta_{[i+1]}^c = \beta_{[i]}^c + \frac{c}{N} [U'(x_{[i+1]}) - U'(x_{[0]})]$$

Le principal problème est de bien choisir le pas de convergence c . Il peut prendre les valeurs suivantes :

- $\frac{1}{i+1}$
- 1 : pas constant
- $\frac{1}{(i+1)^\nu}$ avec $0.5 \leq \nu \leq 1$

Selon le type d'images traitées (images totalement floues, dures ou mélanges des deux), les temps de convergence peuvent être très rapides ou très lents.

Algorithme 2.2 Procédure Gradient Stochastique de Younès

Entrée: $\left\{ \begin{array}{l} x_{[0]} : \text{Configuration Initiale} \\ \beta_{[0]}^c : \text{Potentiels de cliques initiaux} \end{array} \right.$

Pour tout $i = 1 \dots \text{Iterations}$ **Faire**

- Générer un champs de Gibbs $x_{[i]}$ avec les paramètres β^c actuels
- Calcul de $U'(x_{[i]})$
- $\beta_{[i]} \leftarrow \frac{U'(x_{[i]}) - U'(x_{[0]})}{N * (i+1)}$
- $\beta_{[i]} \leftarrow \beta_{[i-1]} + \beta_{[i]}$

Fin Pour

3 Détection des galaxies à faible brillance de surface

3.1 Introduction

Les galaxies à faible brillance de surface[53, 56] (Low Surface Brightness - LSB) sont des galaxies dont la brillance centrale est proche de celle du rayonnement moyen du ciel (entre 23 et 24mag arcsec⁻² en bande *B*) et peut être proche du fond dans l'image. Une galaxie peut être considérée comme une galaxie LSB lorsque $\mu_0 \geq 22\text{mag arcsec}^{-2}$ en bande B où μ_0 est la brillance au centre de la galaxie (figure 3.1).

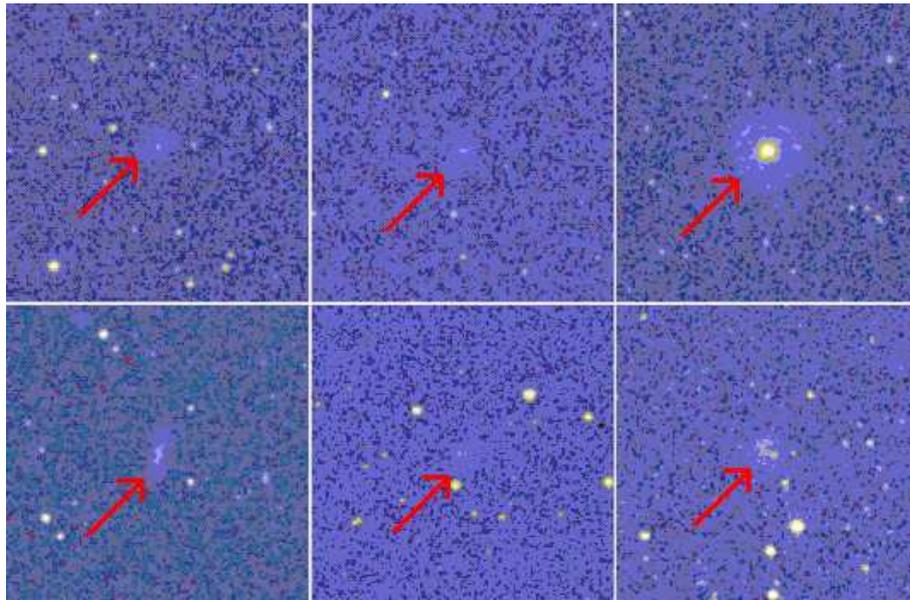


FIG. 3.1 – Images du "Digital Sky Survey" de 6 galaxies LSB dans la bande bleue - Taille des observations : 5×5 minutes d'arc. Sur ces 6 images, on peut remarquer la faible brillance de surface des objets LSB. Cette particularité à laquelle s'ajoute les artefacts d'acquisition de l'image (bruits) rendent ces galaxies difficilement détectables par les algorithmes de détection traditionnels

En dessous d'un certain seuil de brillance (valeur isophotale de brillance), la détection d'objets astronomiques est délicate. De fait, les galaxies LSB ont été découvertes tardivement par Zwicky (1957). Il a également émis l'hypothèse selon laquelle la luminosité du

fond de ciel (l'atmosphère) dans laquelle baignent les galaxies pourrait affecter le nombre de galaxies détectables. En effet, seules les galaxies dont la brillance est supérieure à celle du fond de ciel sont détectables. Cependant, depuis quelques dizaines d'années, les progrès technologiques des capteurs et leur sensibilité grandissante ont permis la découverte de galaxies LSB possédant les mêmes caractéristiques morphologiques que les galaxies normales. Cette diversité est une des raisons pour lesquelles l'étude de ce type de galaxies est cruciale. Il est en effet nécessaire de comprendre pourquoi le mécanisme de formation des étoiles peut conduire à des galaxies avec beaucoup de formations stellaires et d'autres moins (galaxies LSB). De plus, elles offrent une nouvelle vision de la diversité d'évolution et de formes de la population galactique.

La population des galaxies se décompose alors en deux grandes catégories :

- les galaxies “standards” qu'on appellera galaxies HSB (High Surface Brightness) : ces galaxies sont facilement détectables grâce à leur brillance de surface supérieure à la brillance du fond.
- les galaxies à faible brillance de surface.

Les propriétés déduites de l'étude des galaxies HSB[53] permettent de mesurer la taille et la forme de l'univers et d'apporter des indices sur la formation et l'évolution des galaxies, phénomènes encore peu connus de nos jours. Les galaxies HSB et LSB sont les principaux regroupements de matière baryonique rayonnante, la matière baryonique désignant la matière composée de baryons (protons, neutrons, *i.e.* la totalité de la matière ordinaire). La plus grande galaxie à disque connue et la plus riche en hydrogène (au moins $10^{11} M_{\text{sol}} \text{aire}$ soit cinq fois plus que la plupart des galaxies spirales connues) a été découverte par Bothun en 1997 et présente une brillance de surface $\mu_0 = 26.5 \text{mag arcsec}^{-2}$ en bande B. Cette découverte pourrait expliquer la grande partie de la masse baryonique manquante dans l'univers (matière sombre). La connaissance de la densité ainsi que la distribution spatiale des galaxies LSB en dehors du voisinage de la voie lactée sont particulièrement mal connues. La compréhension des propriétés des galaxies LSB et de leur distribution devraient très certainement apporter de nouveaux indices pour comprendre la formation et l'évolution des galaxies. Cependant, l'obtention d'un ensemble de résultats sur de nombreuses galaxies LSB nécessite une étape importante de détection qui se doit d'être la plus complète possible.

Beaucoup de méthodes ont été développées en astronomie afin de créer un catalogue d'objets à partir d'une observation. Les méthodes les plus couramment utilisées consistent à identifier un objet à partir du nombre de pixels connexes au dessus d'un certain seuil (généralement fixé à 2 ou 3 fois l'écart type du fond). Ces méthodes ne sont généralement pas applicables à la détection de galaxies LSB car le seuillage élimine les LSB en même temps que le bruit. Une autre méthode mise en oeuvre par S. Sabatini[59] consiste à convoluer l'image à l'aide de filtres exponentiels multi-échelles (*matched filters*), le profil radial d'une galaxie LSB étant exponentiel décroissant.

L'approche proposée ici consiste à obtenir une carte de segmentation par quadarbre markovien sur une observation monobande, le modèle utilisé ici étant un modèle markovien dur (*cf.* conclusion du chapitre précédent). L'approche markovienne, par une estimation fine du bruit ainsi que la prise en compte d'un voisinage en échelle, permet de détecter des objets visuellement noyés dans le bruit. La carte de segmentation obtenue sert ainsi de masque de sélection sur les observations afin de limiter les traitements aux objets d'intérêts. La première partie de ce chapitre présente donc brièvement les principes de

la segmentation markovienne par quadarbre. Cependant, la segmentation markovienne identifie également dans la carte de segmentation les objets brillants de l'observation. Il convient donc de mettre en place une chaîne de traitements automatiques afin d'éliminer les objets non LSB et de conserver les objets candidats. Cette sélection, présentée dans une deuxième partie, est effectuée à l'aide de critères de taille et par l'analyse approfondie du profil radial de ces objets. Au fur et à mesure des étapes de sélection, un ensemble d'objets potentiellement LSB est donc dégagé et des paramètres astronomiques en sont extraits. Les résultats obtenus sont présentés dans une troisième partie et comparés aux résultats de détection obtenus par S. Sabatini[59] et le logiciel SExtractor ¹ (logiciel de détection d'objets dans une image développé par E. Bertin à l'Institut d'Astrophysique de Paris - IAP).

3.2 Notations utilisées

Notation	Signification
m	Magnitude
F	Flux
F_0	Flux à la magnitude 0
ϵ	Ensemble des paramètres d'une ellipse
(x, y)	Position de l'ellipse
a	Longueur du grand axe de l'ellipse
b	Longueur du petit axe de l'ellipse
α	Angle de position de l'ellipse
ω	Aplatissement de l'ellipse $\rightarrow \frac{b}{a}$
E	Fonction d'erreur
$B_i(r)$	Brillance du secteur i d'une ellipse de rayon r
G	Fonction gaussienne pondérant le calcul de l'erreur E
S	Brillance de surface d'une galaxie LSB
r_0	Rayon caractéristique d'une LSB
A, μ_0	Brillance au centre de la galaxie

3.3 Segmentation markovienne par quadarbre

Un quadarbre $T = (S, L)$, composé d'un ensemble S de noeuds et L de liens entre les noeuds, est un arbre dans lequel chaque noeud $s \in S$ est relié, mise à part la racine r , à un unique prédécesseur s^- appelé noeud *parent*. De plus, chaque noeud s est directement en relation avec ses 4 *enfants* s^+ (sauf pour les noeuds terminaux ou *feuilles*). Chaque étage dans cette pyramide correspond alors à une échelle, l'ensemble des sites s à l'échelle n est noté S^n , S^r correspondant à la racine et S^0 à l'échelle la plus fine.

Le champ des étiquettes X est ici supposé markovien en échelle. On peut donc écrire :

$$P(x^n | x^k, k > n) = P(x^n | x^{n+1}) \quad (3.1)$$

où x^n est le champ des étiquettes à l'échelle n . Ainsi, le champ des étiquettes à l'échelle n dépend uniquement de son parent à l'échelle x^{n+1} . On peut alors écrire la probabilité

¹http://terapix.iap.fr/rubrique.php?id_rubrique=91/

de transition inter-échelles[42, 36] sous la forme factorisée suivante :

$$P(x^n|x^{n+1}) = \prod_{s \in S} P(x_s|x_{s-}) \quad (3.2)$$

On peut également écrire la vraisemblance des observations y conditionnellement à x :

$$P_{Y|X}(y|x) = \prod_{n=0}^r P(y^n|x^n) = \prod_{n=0}^r \prod_{s \in S} P(y_s|x_s) \quad (3.3)$$

où $\forall s \in S^n, \forall n \in \{0, \dots, r\}, P(y_s|x_s = \omega_i) \triangleq f_i^n(y_s)$ est la vraisemblance de l'observation y_s . Ce terme de vraisemblance peut être modélisé de différentes manières : nous nous plaçons ici dans le cas gaussien. On peut, à partir de ces hypothèses, exprimer la distribution jointe $P_{X,Y}(x, y)$ sous la forme factorisée suivante[36] :

$$P_{X,Y}(x, y) = \prod_{n=0}^r P(y^n|x^n) = \prod_{n=0}^r \prod_{s \in S} P(y_s|x_s) P(x_r) \prod_{s \neq r} p(x_s|x_{s-}) \prod_{s \in S} P(y_s|x_s) \quad (3.4)$$

où $P(x_r = \omega_i) = \pi_i$ est la probabilité *a priori* du champ des étiquettes et $P(x_s = \omega_j|x_{s-} = \omega_i) = a_{ij}$ est la probabilité de transition parent/enfant.

Le modèle de quadarbre markovien nécessite donc l'estimation de deux jeux de paramètres :

- les paramètres θ_x du modèle *a priori* :
 - les probabilités *a priori* $\{\pi_i\}_{i=1, \dots, K}$ de passage à l'échelle ;
 - les probabilités de transition parent/enfant : $\{a_{ij}\}_{i,j=1, \dots, K}$;
- les paramètres θ_y des vraisemblances. θ_y dépend du modèle de bruit choisi (loi d'attache aux données).

Les différentes techniques d'estimation de ces paramètres ainsi que l'utilisation de modèles différents du modèle classique gaussien sont décrits dans [23].

Les observations sont donc segmentées en utilisant l'approche par quadarbre (figure 3.2).

Le nombre de classes a été fixé (par Bernd Vollmer, astronome au CDS de Strasbourg) à 6 classes dures, permettant ainsi de dégager les objets dont la distribution de luminosité est proche de celle du fond. Ce nombre de classes a été déterminé en fonction des différents types d'objets présent dans les observations (LSB, HSB, étoiles,...). Lorsque le nombre de classes est inférieur à 6, certains objets ne sont pas correctement segmentés tandis que si il dépasse 6 on peut alors observer une sur-segmentation du fond de l'image. L'augmentation du nombre de classes se traduit, pour les observations INT, à la création de nouvelles classes de luminosité forte, en sur-segmentant les objets brillants. Dans le cas d'images majoritairement composée d'objets très brillants (HSB, étoiles), la segmentation sera dominée par la forte luminance de ces objets et les 6 classes seront réparties entre les objets brillants, classifiant les galaxies LSB comme appartenant au fond.

La carte de segmentation obtenue joue alors le rôle de masque sur l'observation afin d'effectuer une série de sélections basées sur des critères morphologiques (notamment de taille), de luminosité (par un calcul de la magnitude de chaque objet), ainsi que sur la forme du profil radial de chacun des objets.

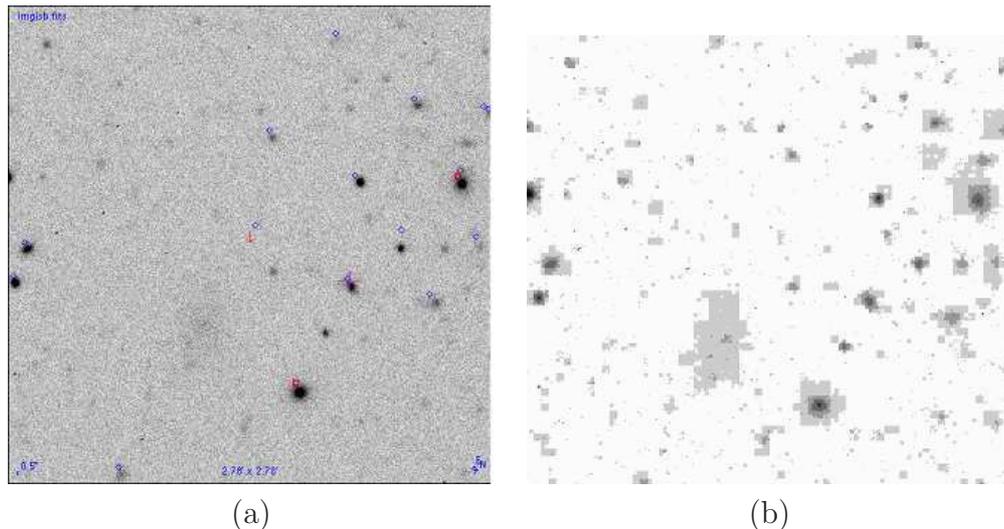


FIG. 3.2 – (a) : observation monobande, taille 256×256 , bande B, amas de la Vierge. (b) : carte de segmentation avec $k = 6$. On peut remarquer que certains objets difficilement visibles à l’œil nu sont présents dans la carte de segmentation, notamment l’objet central étendu présent dans la carte de segmentation.

3.4 Détection des galaxies LSB

La carte de segmentation obtenue sur le quadarbre markovien n’est pas uniquement composée de galaxies LSB. En effet, de nombreuses galaxies HSB et étoiles y sont présentes. Il est donc nécessaire de définir des critères permettant la sélection des objets candidats LSB. Cependant, ces critères nécessitent un travail préalable sur les observations INT. Par exemple, le calcul de la magnitude de chaque objet nécessite une suite d’opérations sur les observations appelées réduction photométrique. Les coordonnées de chaque objet doivent également être connues, afin par exemple, de comparer les résultats de détection obtenus avec des catalogues existants, ou tout simplement pour la présentation et l’interprétation des résultats. Cette étape de calibration ainsi que le calcul de la photométrie sont présentées dans la section suivante, puis l’algorithme de détection des galaxies LSB est présenté dans une seconde section.

3.4.1 Traitements “astronomiques” des observations INT

3.4.1.1 Réduction photométrique

En astronomie, la magnitude apparente est une mesure quantifiant la luminosité mesurée, depuis la terre, d’un objet astronomique. Cette échelle est logarithmique et inversée. Ainsi les magnitudes les plus faibles (*resp.* fortes) correspondent à des objets de forte luminosité (*resp.* peu lumineux). L’augmentation d’une magnitude (de m à $m + 1$) correspond à un objet 2.5 fois moins lumineux.

Une magnitude s’exprime sous la forme suivante :

$$m = -2.5 \log_{10} \left(\frac{F}{F_0} \right) \quad (3.5)$$

où F est un flux et F_0 une constante de calibration. La constante F_0 est inconnue et reste donc à déterminer. Les valeurs des pixels des observations sont proportionnels à un flux F . Il n'est donc pas envisageable d'utiliser les valeurs des pixels comme valeur de flux dans le calcul de la magnitude. De plus chaque objet, étant résolu spatialement, la valeur de luminosité en chaque pixel n'est pas représentative de la luminosité totale de l'objet. SExtractor permet alors d'extraire une valeur de flux intégrée (F) sur chacun des objets qu'il détecte dans l'observation. L'utilisation de catalogues astronomiques de standards photométriques (UCAC², USNO³) nous donne accès à l'information de magnitude pour chacun des objets présent conjointement dans l'observation et dans le catalogue. En utilisant les magnitudes ainsi que les valeurs de flux déterminées par SExtractor, nous pouvons déterminer F_0 à partir de l'équation 3.5. La magnitude est ainsi calculable pour les objets non référencés dans les catalogues astronomiques.

3.4.1.2 Astrométrie

La réduction astrométrique consiste à déterminer avec précision la position des objets (exprimée dans les unités astronomiques usitées) dans une image. Ce recalage consiste donc à convertir une position (x, y) dans un système de coordonnées équatoriales (déclinaison, ascension droite), exprimées en degrés, minutes et secondes d'arcs. La partie *en-tête* des fichiers FITS (format d'échange standard en astronomie) contient généralement une matrice permettant d'exprimer les coordonnées (x, y) des pixels dans les unités astronomiques en fonction d'un point de référence (situé dans l'image ou pas). Cependant, cette conversion peut aboutir à des coordonnées différentes des catalogues astronomiques standards. On assiste alors à un décalage entre les positions des objets de l'observation et les positions des objets dans le catalogue. La réduction astrométrique consiste, à partir des positions du catalogue et des objets dans l'observation, à calculer une nouvelle matrice de transformation qui sera injectée dans l'*en-tête* du fichier FITS. Cette transformation s'effectue manuellement (en utilisant le logiciel Aladin par exemple) et consiste à déterminer une matrice minimisant l'écart entre les deux systèmes de coordonnées différents au sens des moindres carrés. Néanmoins, le décalage entre les objets peut varier selon la zone de l'image. Le résultat obtenu par la méthode des moindres carrés peut alors être toujours incohérent avec le catalogue dans les zones de grands décalages. D'autres techniques de recalage astrométrique existent mais leur mise en oeuvre peut devenir rapidement complexe. Afin de recalibrer les observations INT, nous avons donc utilisé la méthode des moindres carrés fournies automatiquement par Aladin.

3.4.2 Elimination d'objets dans la carte de segmentation

La carte de segmentation obtenue précédemment par quadarbre, permet d'obtenir, sur une seule carte, un ensemble de régions. Les galaxies LSB répondant, pour des galaxies spirales, à des critères spécifiques de taille, une première étape dans la détection de celles-ci consiste à travailler uniquement sur les objets dégagés par la segmentation markovienne et d'introduire un ensemble de critères morphologiques afin d'éliminer les objets ne répondant pas aux critères des galaxies LSB :

²<http://ad.usno.navy.mil/ucac/>

³<http://www.usno.navy.mil/>

1. la carte de segmentation est binarisée, *i.e.*, les classes supérieures ou égales à 1 prennent la valeur 1 ;
2. une ouverture ainsi qu’une fermeture (au sens de la morphologie mathématique) successives sur les observations vont permettre d’éliminer les objets très petits (de l’ordre du pixel) et de combler les ”trous” pouvant apparaître au sein des objets. L’ouverture d’une image lisse les contours en éliminant les petites convexités, mais pas les concavités. La fermeture d’une image lisse les contours en éliminant les concavités, mais pas les convexités. Cette étape d’ouverture-fermeture correspond, du point de vue traitement astronomique, à l’application d’un filtre médian suivi d’une interpolation sur la carte de segmentation. A l’issue de ces deux étapes, les objets très petits, assimilés au bruit, sont éliminés de la carte de segmentation.
3. les très petites structures ont peu de chance d’être des galaxies LSB, et certaines n’ont pas été supprimées par l’étape précédente. Il convient alors de modéliser chacun des objets présents dans la carte de segmentation avec une ellipse, de calculer la longueur de son grand axe, et de définir une longueur minimale en deçà de laquelle l’objet est éliminé (on prendra 3 fois l’écart-type de la PSF de l’image : environ 8 pixels (soit 2,6 secondes d’arc), la PSF variant finement entre chaque observation). Une étape complémentaire consiste à introduire un critère de taille maximale. Toutes les structures dont la longueur du grand axe dépasse 300 pixels sont alors éliminées (le temps de calcul de l’algorithme de détection sur un tel objet est de quelques minutes).
4. les objets près du bord de l’observation (moins de 64 pixels) sont éliminés pour la recherche des LSB. En effet, une grande partie de sa structure peut être tronquée par les bords de l’image. Il est donc ainsi difficile de se livrer à des traitements sur un tel objet ;

La figure 3.3, présente un exemple de ces sélections sur une observation.

L’ensemble de ces critères de taille a permis d’éliminer les objets trop petits ou trop grands de la carte de segmentation. Dorénavant, la sélection s’effectuera à partir du profil radial de luminosité de chacun des objets restants. Une première ellipse modélisant chaque objet est obtenue (fonction matlab) initialement sur chaque objet. Cette ellipse “calquant” chaque objet, il est désormais possible d’obtenir le profil de brillance de surface de chaque objet et de mettre en place un ensemble de critères sur ces profils. Cependant, la première ellipse n’étant pas optimale, *i.e.*, basée uniquement sur le contour externe mal défini de l’objet dans l’image binarisée, il est nécessaire d’optimiser les paramètres de l’ellipse en fonction d’un critère astronomique. Un algorithme de gradient adaptatif est alors utilisé afin d’optimiser les paramètres de chaque ellipse en minimisant une fonction d’erreur E basée sur une propriété de symétrie en luminosité de la galaxie LSB.

3.4.3 Optimisation des paramètres de chaque ellipse

Une ellipse est définie par les paramètres suivant (figure 3.4) :

$$\epsilon = (x, y, a, b, \alpha, \omega) \quad (3.6)$$

où :

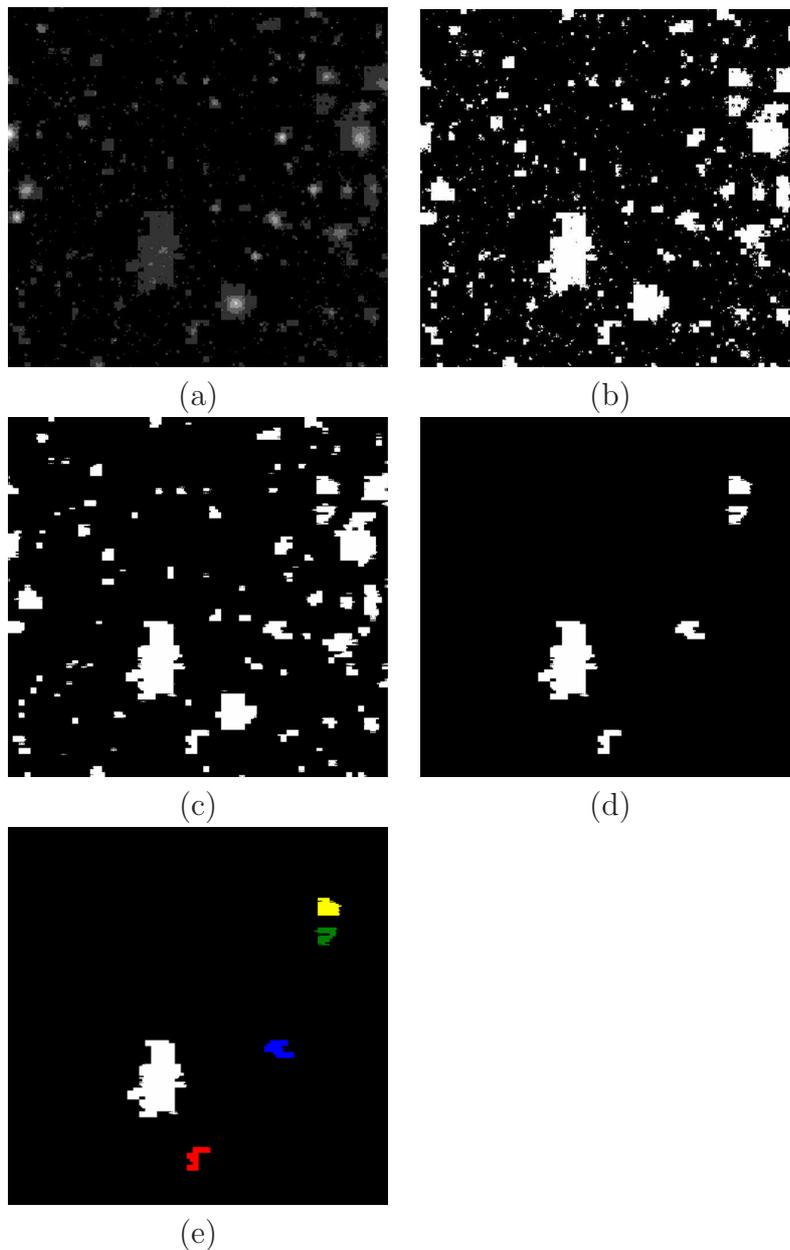


FIG. 3.3 – (a) : carte de segmentation obtenue sur le quadarbre markovien. (b) : Binarisation de la carte de segmentation. (c) : Erosion suivie d’une dilatation afin d’éliminer les objets de très petites tailles. (d) : élimination des objets dont la taille du grand axe majeur de l’ellipse est inférieure à $3 \times \sigma(PSF)$ et supérieure à 300 pixels et élimination des objets proches du bord dont le centre de l’ellipse extrapolée est située à moins de 64 pixels du bord de l’image. (e) : Assignment d’une classe arbitraire à chacun des objets restants afin de faciliter leurs traitements.

- (x, y) sont les coordonnées du centre de l'ellipse ;
- a la longueur du grand axe ;
- b la longueur du petit axe ;
- α l'angle de position ;
- ω l'aplatissement correspondant à $\frac{b}{a}$.

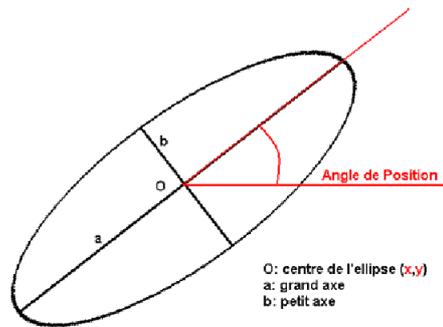


FIG. 3.4 – Définition d'une ellipse

On découpe alors l'ellipse extrapolée sur l'objet en quatre secteurs répartis autour des demi-grands et demi-petits axes. En faisant l'hypothèse, astronomique, que la brillance de surface est homogène sur un rayon donné dans une galaxie LSB (*i.e.* la galaxie est symétrique par rapport à son centre en luminosité), on peut alors définir une fonction d'erreur E prenant en compte la différence entre les brillances dans chaque portion (suivant les quatre demi-axes) de l'ellipse (figure 3.5).

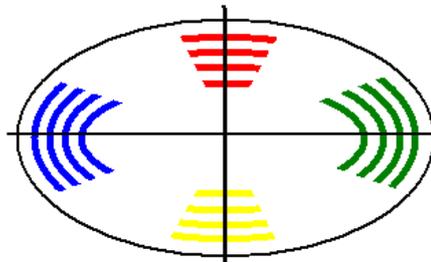


FIG. 3.5 – Découpage de l'ellipse en 4 secteurs suivant les 4 demi-axes (4 couleurs différentes). Pour chaque rayon r , la brillance de surface doit être identique pour chaque secteur.

La première ellipse extrapolant l'objet est appelée *ellipse majeure* tandis que les différentes ellipses de rayon r incluses dans l'ellipse majeure sont appelées *ellipses mineures*.

La fonction d'erreur peut alors s'exprimer comme suit :

$$E(x, y, \alpha, b) = \sum_{r=0}^{2a} \sum_i \sum_j |B_i(r) - B_j(r)| \quad (3.7)$$

où $B_i(r)$ correspond à la brillance du secteur i pour un rayon r (E ne dépend pas de a car il est fixé dans notre méthode). Le calcul de $B_i(r)$ s'effectue en moyennant les pixels appartenant au secteur i . Afin de réduire le bruit lors du calcul de la brillance d'un secteur, un filtre moyennneur est appliqué pour chaque position dans le secteur :

$$F = \begin{bmatrix} \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \end{bmatrix} \quad (3.8)$$

Les portions d'ellipses les plus représentatives de l'objet considéré sont situées près du centre de la galaxie. On va donc donner un poids aux erreurs en fonction du rayon de chaque ellipse mineure. On choisit pour cela une fonction gaussienne $G(r) = \exp(\frac{-r^2}{2a})$, où a est la longueur du grand axe de l'ellipse considérée, dont le maximum sera atteint pour $r=0$, et décroissant progressivement quand r augmente. Afin de déterminer l'ellipse la plus optimale au sens de notre critère de symétrie en luminosité, il suffit alors de minimiser E , ce qui revient alors à un problème d'optimisation de paramètres classique. Différentes méthodes d'optimisation ont été testées afin de minimiser E :

- calcul de E sur une grille discrète. Dans cette méthode, chaque paramètre de l'ellipse peut varier entre deux bornes prédéfinies. L'erreur est alors calculée pour toutes les valeurs possibles de chacun des paramètres. Cette méthode effectue un parcours exhaustif de l'espace des solutions mais est extrêmement coûteuse en temps de calcul (environ 1 min par objet) ;
- méthode du gradient adaptatif. Cette méthode consiste à calculer le gradient de la fonction d'erreur afin de déterminer la direction de la plus grande pente de la fonction E puis de mettre à jour les paramètres de telle sorte que la nouvelle erreur soit plus petite que la précédente (annulation du gradient de E). Cette méthode est très utilisée mais son application dans un espace de dimension 4 est délicate. En effet, la surface définie par la fonction d'erreur peut être complexe et éventuellement contenir un grand nombre de minima locaux. Cette méthode n'a donc pas été retenue ;
- optimisation par algorithme génétique. Les algorithmes génétiques sont des méthodes, issues de l'intelligence artificielle, permettant de minimiser une fonction d'erreur. Ils consistent à définir un ensemble d'individus (chromosomes) potentiellement solutions du problème, puis, à déterminer l'individu minimisant la fonction d'erreur E par une série de croisements et de mutations entre les meilleurs individus (minimisant au mieux la fonction E). Cette méthode est généralement utilisée pour son parcours fin de l'espace des solutions mais est très lente en terme de temps de calcul. De plus, le nombre de paramètres de l'algorithme génétique est généralement élevé (6 ou 7) et nécessite une bonne connaissance du fonctionnement de ce type d'algorithmes ;
- méthode de gradient adaptatif par paramètre. Cette méthode consiste à faire varier un des quatre paramètres (x, y, α, b) en fixant les autres afin de minimiser E par rapport à ce paramètre. L'algorithme du gradient est alors réitéré en faisant varier à chaque fois un seul des quatre paramètres. Nous avons retenu cette méthode dans notre algorithme d'optimisation des paramètres de chaque ellipse (Algorithme 1). En effet, le temps de calcul de cette méthode est court (environ 10 secondes par objet) et sa mise en oeuvre aisée.

Algorithme 3.1 Algorithme du gradient adaptatif

Entrée: (x, y, α, b) : paramètres de l'ellipse
 i : nombre d'itérations

Pour tout i Faire

- x varie et (y, α, b) sont fixes
- $x_i = \operatorname{argmin}_x E(x, y, \alpha, b)$
- y varie et (x, α, b) sont fixes
- $y_i = \operatorname{argmin}_y E(x_i, y, \alpha, b)$
- α varie et (x, y, b) sont fixes
- $\alpha = \operatorname{argmin}_\alpha E(x_i, y_i, \alpha, b)$
- b varie et (x, y, α) sont fixes
- $b_i = \operatorname{argmin}_b E(x_i, y_i, \alpha_i, b)$
- $(x, y, \alpha, b) \leftarrow (x_i, y_i, \alpha_i, b_i)$

Fin Pour

Le calcul de l'erreur sur chaque secteur peut être erroné dans le cas où un de ces secteurs chevauche un objet voisin proche. Afin d'éviter cette configuration, chaque secteur rencontrant un objet proche (un objet de classe différente de l'objet étudié) n'est plus pris en compte dans le calcul de E . Dans le cas où un objet est entouré dans les quatre directions, le nombre de secteurs sera insuffisant et l'objet ne sera pas traité. Dans le cas d'objets proches des bords de l'image, le secteur "sortant" de l'observation n'est également plus pris en compte lorsque celui-ci croît.

Une fois les paramètres de l'ellipse correctement estimés, l'obtention du profil de brillance de surface consiste à moyenniser les intensités pour chaque rayon de l'ellipse (en considérant cette fois-ci, la totalité de l'ellipse de rayon r). Un exemple de profil de brillance de surface est présenté figure 3.6.

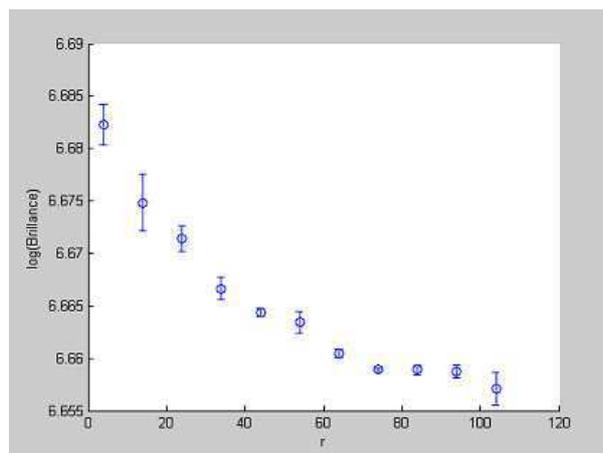


FIG. 3.6 – Profil de brillance de surface d'une galaxie. Les barres d'erreurs correspondent à l'écart-type entre la valeur de la brillance calculée sur toute l'ellipse de rayon r et les quatre valeurs de chacun des quatre secteurs pour le même rayon.

Un profil de brillance de surface (figure 3.6) est la combinaison de 3 courbes (figure 3.7) :

- la brillance du bulbe de la galaxie ;
- la brillance du disque la galaxie ;
- le bruit présent dans l'image ;

La brillance de surface du disque de la galaxie est modélisée par une fonction de la forme :

$$\mathcal{S}(r) = A \times \exp\left(-\frac{r}{r_0}\right) \quad (3.9)$$

où A désigne la brillance au centre de la galaxie, $-\frac{1}{r_0}$ le coefficient de décroissance de la luminosité et r_0 le rayon caractéristique de la galaxie.

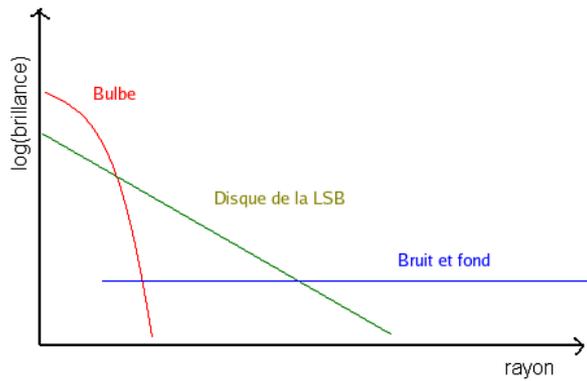


FIG. 3.7 – Composition d'un profil de brillance de surface d'une galaxie

Afin de détecter les galaxies LSB, la brillance de surface du disque de la galaxie $\mathcal{S}(r)$ est seulement prise en compte. Une étape préalable à une régression linéaire sur les points susceptibles d'appartenir au disque de la galaxie, consiste à estimer la valeur du bruit, pour éliminer les points du profil inférieurs à la brillance de celui-ci. L'estimation du bruit se fait en calculant la moyenne μ de l'image ainsi que son écart-type σ (en prenant en compte uniquement les pixels appartenant à la classe 0 dans la carte de segmentation). On considère alors que tous les pixels dont la valeur est inférieure à $\mu + 3\sigma$ appartiennent au bruit. La moyenne du bruit est ainsi calculée uniquement sur les pixels associés au bruit. Puis, les points du profil inférieurs à la moyenne du bruit sont éliminés.

Une simple régression linéaire est ensuite effectuée sur le profil épuré de la galaxie pour estimer la brillance de son disque. Un minimum de 3 points présents sur la droite estimée est requis pour accepter l'objet en tant que galaxie LSB. En échelle logarithmique, on peut écrire :

$$\log(\mathcal{S}(r)) = \log(A) - \frac{r}{r_0} \quad (3.10)$$

La régression linéaire exprime $\log(\mathcal{S}(r))$ sous la forme d'une fonction affine $ax + b$. Ainsi le coefficient directeur a de la droite obtenue correspond à $-\frac{1}{r_0}$ tandis que l'ordonnée à l'abscisse b correspond à $\log(A)$. Les galaxies elliptiques sont des galaxies uniquement composées d'un bulbe (dont la luminosité décroît radialement selon une fonction exponentielle). Afin de détecter la présence de telles galaxies une régression linéaire sur le

profil en $\log(r)$ et $\log(S(r))$ est également effectuée. Si au moins une des deux régressions linéaires (linéaire-logarithmique et logarithmique-logarithmique) a abouti, la galaxie est sélectionnée comme étant une galaxie potentiellement LSB.

3.5 Résultats de détection

3.5.1 Données utilisées

Les observations utilisées dans ce chapitre ont été fournies et préalablement étudiées par S. Sabatini (Observatoire astronomique de Rome) ainsi que Wim Van Driel (Institut d'astrophysique de Paris). Elles proviennent du Isaac Newton Telescope Wide Field Camera Survey (INT WFC⁴) qui est un relevé grand champ basé sur un capteur CCD multi-couleur. Ce relevé couvre de nombreuses zones du ciel (Coma, amas Virgo...) couvrant au total 200deg^2 (figure 3.8).

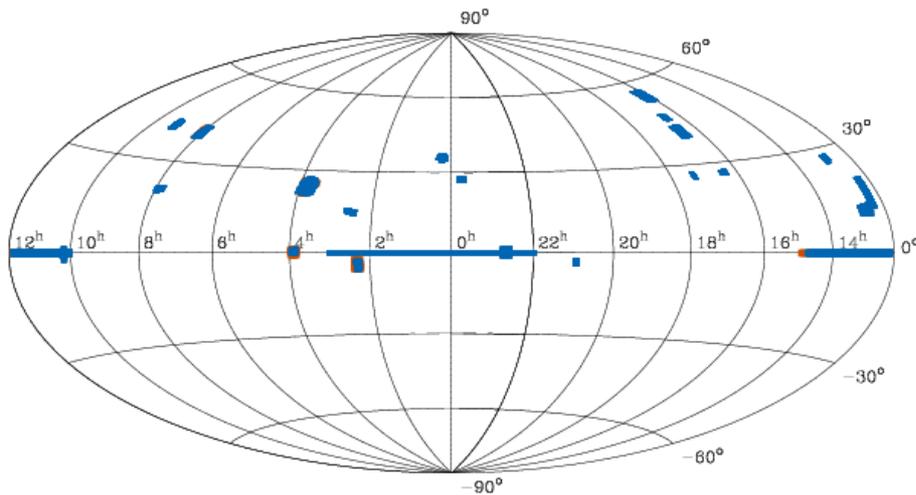


FIG. 3.8 – Couverture du relevé WFC (1998). En bleu les zones observées. En rouge, les zones non observées pour le moment

Chaque portion du ciel est observée à l'aide de 4 CCD dans 4 couleurs différentes (bandes U , B , I , et Z)⁵ et la résolution d'un pixel est de 0.33 arcsec. Pour notre étude, une approche monobande a été retenue en étudiant uniquement la bande B (les possibilités d'analyse multibande sont abordées en conclusion de ce chapitre). Nous disposons donc de 80 images de taille 4000×2100 pixels pour lesquelles un catalogue de galaxies LSB détectées par S. Sabatini est accessible, permettant la comparaison entre notre méthode et celle développée par S. Sabatini.

Etant donné la grande taille des images 2048×4100 pixels, celles-ci sont préalablement découpées en imagerie de 256×256 pixels. Chacune des imagerie a une partie commune avec ses imagerie voisines appelée zone de recouvrement (128 pixels). Ce recouvrement

⁴<http://www.ast.cam.ac.uk/wfcSUR/index.php>

⁵<http://www.ing.iac.es/Astronomy/instruments/wfc/index.html>

permet de traiter les objets présents à la frontière des imajettes et qui auraient été tronqués par le découpage (figure 3.9).

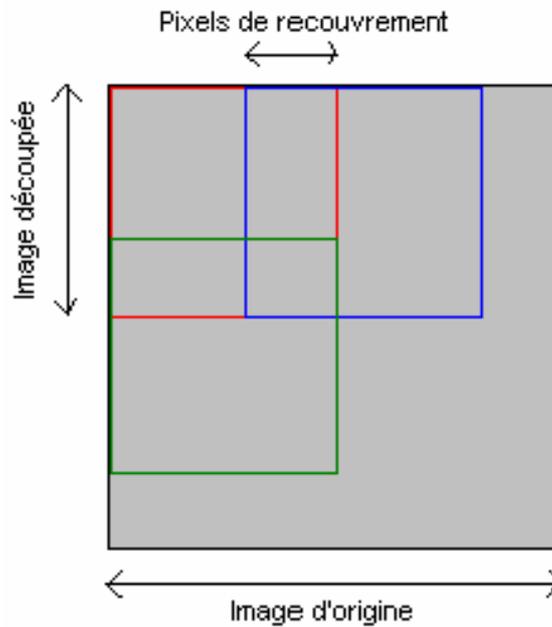


FIG. 3.9 – Découpage d’une observation en imajettes.

3.5.2 Résultats

Sur les 80 images à disposition, nous avons traité 18 d’entre elles. Le nombre d’objets candidats détectés par notre algorithme est de 246. Le fichier de résultats étant volumineux, nous présentons uniquement ici quelques résultats types de détection.

Les figures 3.10 et 3.11 présentent les résultats de détection de 9 objets et le tableau 3.1 leurs propriétés directement déduites de notre algorithme.

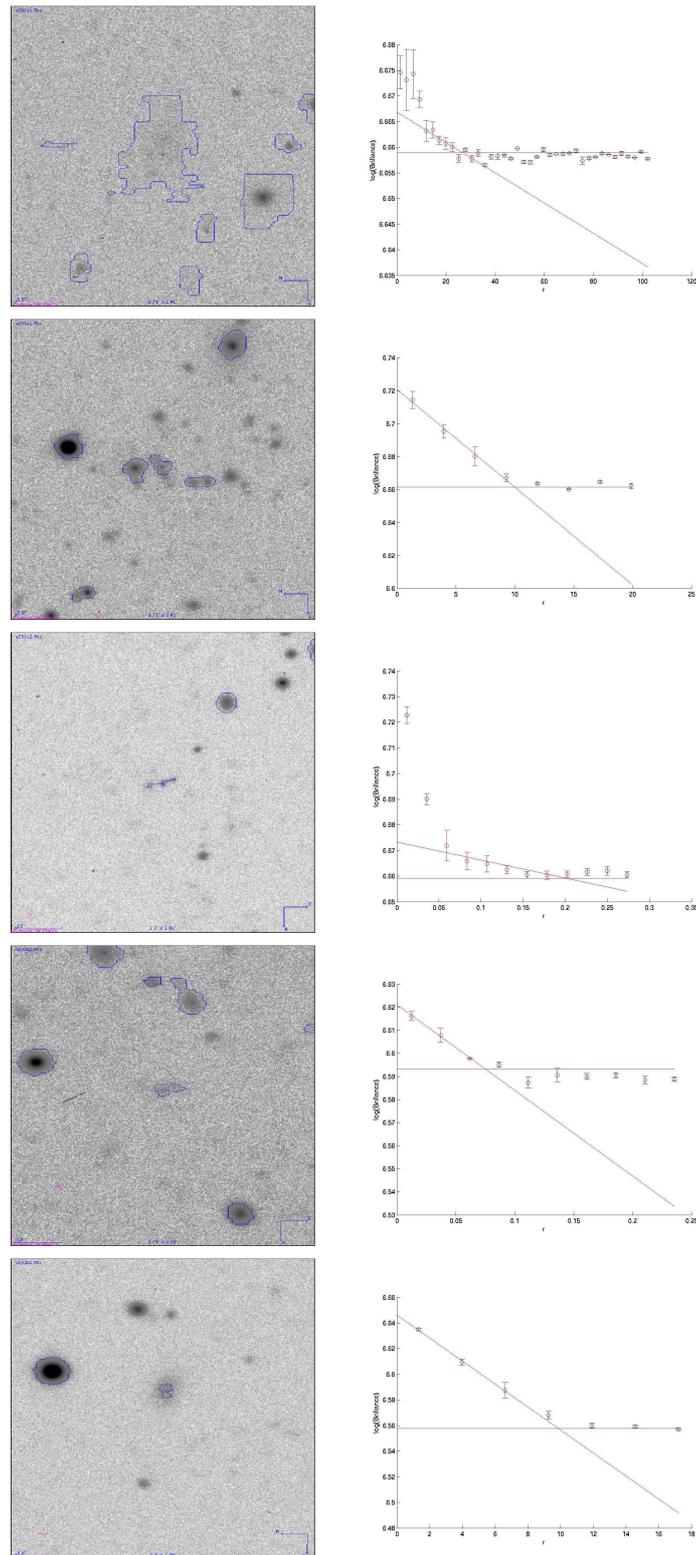


FIG. 3.10 – Résultats de détection de galaxies LSB. Chaque ligne correspond à un objet. La première colonne contient une imagerie de l'observation centrée sur la LSB détectée. Le contour en bleu correspond au contour de l'objet dans la carte de segmentation. Le curseur bleu correspond au centre de la LSB. La deuxième colonne contient les profils de chacun des objets détectés. La droite rouge horizontale sur le profil correspond au niveau du bruit dans l'image et la droite en rouge oblique correspond à la droite obtenue avec la régression linéaire.

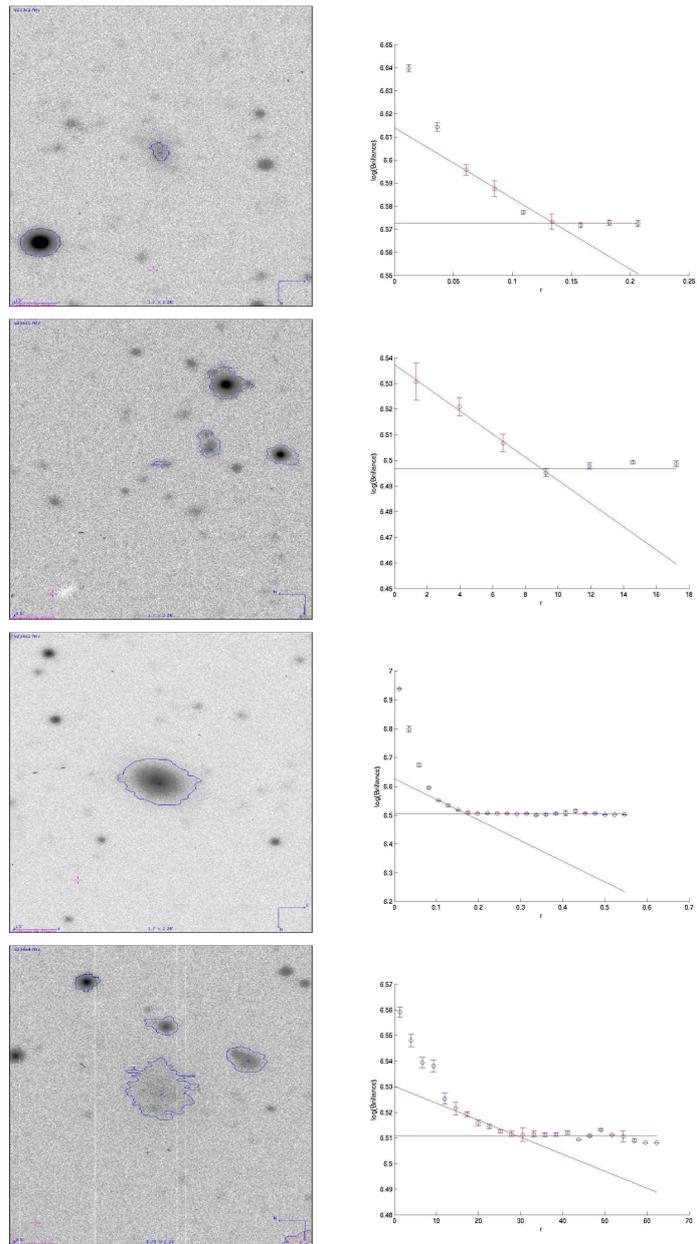


FIG. 3.11 – Résultats de détection de galaxies LSB - suite.

N	Image	Centre	b	a	ω	α	μ_0	r_0
1	v231c1.fits	12 :32 :15 - 10 :56 :19	28.173	42.094	60	189	26.5	25.2
2	v231c1.fits	12 :32 :9 - 10 :52 :9	4.640	8.618	48	40	24.4	9.9
3	v231c2.fits	12 :30 :21 - 11 :8 :47	0.027	0.119	20	112	25.4	0.2
4	v232c2.fits	12 :32 :43 - 11 :4 :5	0.046	0.099	42	98	24.1	0.1
5	v233c1.fits	12 :36 :36 - 10 :59 :27	6.287	7.941	71	20	25.8	9.6
6	v233c2.fits	12 :34 :41 - 11 :8 :34	0.070	0.091	69	32	23.9	0.1
7	v234c1.fits	12 :38 :47 - 10 :56 :42	2.979	7.945	33	103	24.2	8.9
8	v234c2.fits	12 :37 :17 - 10 :53 :20	0.169	0.227	66	67	25.3	0.2
9	v234c4.fits	12 :38 :17 - 11 :10 :48	21.213	26.185	72	28	25.2	26.8

TAB. 3.1 – Propriétés des objets détectés des figures 3.10 et 3.11. N : numéro de l’objet. *Image* : nom de l’image sur laquelle l’objet a été détecté. *Centre* : centre de l’objet dans l’image. b : longueur du petit axe de l’ellipse en arcseconde. a : longueur du grand axe de l’ellipse en arcseconde. ω : aplatissement de l’ellipse. α : angle de position en degrés. μ_0 : magnitude de la galaxie LSB en $mag.arcsec^{-2}$. r_0 : rayon caractéristique de la galaxie en arcseconde.

Pour l’objet 1, il est difficile, à l’oeil nu, de détecter la présence d’une galaxie LSB. En effet, l’algorithme a mis en valeur une galaxie LSB très étendue ($25.2arcsec$) et dont la magnitude est très faible ($26.5mag.arcsec^{-2}$), bien en dessous de la limite isophotale fixée à $22mag.arcsec^{-2}$. Le quadarbre markovien a donc correctement segmenté cet objet en le dégagant du fond. Le profil de l’objet 1 confirme la présence d’une galaxie LSB.

On peut remarquer, pour l’objet 2, que l’algorithme de détection a été capable de traiter deux objets proches. Cela se retrouve également dans le profil dont on peut remarquer qu’il reste toujours décroissant. La prise en compte des objets voisins dans l’algorithme de détection aurait conduit à un profil piqué dès lors que les ellipses mineures atteignent un objet voisin de luminosité forte.

L’objet 4, de très petite taille, montre la capacité de l’algorithme à travailler sur des objets particuliers tandis que l’objet 9 est un objet de très grande taille difficilement visible sans réhausser fortement le contraste de l’image.

Dans les deux sections suivantes, nous comparons les résultats obtenus avec trois détections obtenues par S. Sabatini ainsi que le logiciel Sextractor.

3.5.3 Comparaisons avec la détection de S. Sabatini

La méthode utilisée par S. Sabatini consiste à convoluer l’image avec une série de filtres exponentiels à des échelles différentes.

Sur les 246 objets détectés par notre méthode, 106 sont des galaxies LSB, les 140 objets restants étant des galaxies HSB ou bien des étoiles. Sur le même jeu de données utilisés, S. Sabatini a détecté 37 galaxies LSB. En comparant les données de S. Sabatini aux nôtres, nous obtenons les statistiques suivantes :

- 9 galaxies LSB apparaissent en commun dans les deux détections (24 %) ;
- 16 galaxies LSB ont été éliminées de la carte de segmentation par nos critères de tailles (43 % - 3 trop grandes et 13 trop petites) ;

- 3 galaxies ont été éliminées car le nombre de points dans leur profil est trop faible pour se livrer à une régression linéaire (8 %);
- 3 galaxies n’ont pas été détectées puisqu’elles ont été éliminées car trop proches du bord de l’image originale (8 %);
- 6 n’apparaissent pas dans la carte de segmentation issue de l’algorithme markovien (16 %).

On peut remarquer que beaucoup de galaxies LSB ont été éliminées sur un critère de taille (16 galaxies). Diminuer la contrainte de taille minimale et augmenter celle de la taille maximale pourrait permettre la détection de ces objets par notre méthode. Lors de nos expérimentations, la relaxation de ces critères conduit à l’apparition de nombreux petits objets correspondant, parfois, au bruit de l’observation. Ainsi, lors de l’étape d’optimisation des paramètres de l’ellipse pour un objet, le calcul des secteurs devient problématique puisque chaque galaxie LSB est alors encerclée par un ensemble de petites classes associées au bruit. Le calcul de l’erreur sur chaque secteur étant stoppé dès la rencontre d’un objet, le profil ne comportera pas assez de points pour se livrer à une régression linéaire.

Les 3 galaxies proches du bord ne peuvent pas être détectées par notre méthode. Il serait alors nécessaire de déterminer l’image voisine de l’image en cours puis d’extraire “l’image frontière” des deux images. Les objets incriminés ne seront donc plus tronqués et la détection est rendue possible.

Afin de résoudre le problème des 6 galaxies LSB non présentes dans la carte de segmentation, il faut se livrer à un ensemble d’optimisation sur l’algorithme markovien. En effet, ces galaxies n’ont pas été détectées à cause de leur très faible brillance de surface. La présence proche d’objets brillants dans la même image influence l’algorithme markovien qui va répartir un grand nombre de classes parmi les objets brillants. Il ne restera alors plus assez de classes à distribuer pour faire ressortir les objets très faibles qui seront assimilés à du bruit et donc à la classe “fond”. Une première solution consisterait à masquer les objets brillants (à l’aide d’une détection préalable de ceux-ci par Sextractor par exemple) puis à effectuer une segmentation sur les images épurées. Cependant, la mise en oeuvre de cette méthode conduit à une sur-segmentation du fond et à l’apparition de halo de classes autour des objets brillants masqués. Une deuxième solution simple consiste à simplement augmenter le nombre de classes de la carte de segmentation mais conduit également à une sur-segmentation du fond de l’observation. Les galaxies LSB sont alors entourées et incluses dans une ou plusieurs classes et leur sélection est délicate. Une dernière solution, certainement la plus pertinente, consisterait à utiliser une deuxième image mais à une longueur d’onde différente. La segmentation deviendrait alors multibande et l’apport d’information de la deuxième bande permettrait de détecter de tels objets.

On peut remarquer que notre algorithme à détecter de nombreuses LSB supplémentaires par rapport à l’approche de S. Sabatini. Ces galaxies ont été déterminées sur des critères visuels de forme de profil. Les deux méthodes sont donc complémentaires.

3.5.4 Comparaisons avec la détection de Sextractor

L’utilisation de Sextractor sur les images originales permet la construction d’un catalogue d’objets. La détection effectuée par Sextractor est robuste pour les objets brillants mais peut être erronée dans le cas d’objets à brillance très faibles. En effet, Sextractor

a tendance à détecter plusieurs objets à l'intérieur d'un objet de brillance faible. Sur les 106 galaxies détectées par notre méthode, Sextractor en détecte 75 :

- en prenant en compte les galaxies elliptiques uniquement (régression linéaire en échelle logarithmique-logarithmique), Sextractor en détecte 53 sur 60 du fait de leur brillance de surface généralement plus élevée que celle des galaxies non-elliptiques ;
- en prenant en compte les galaxies non-elliptiques uniquement (régression linéaire en échelle linéaire-logarithmique), Sextractor en détecte 22 sur 46 ;

On peut remarquer à partir de ces résultats que Sextractor détecte mal les galaxies non-elliptiques (moins de la moitié détecté). Les quelques détections effectuées par Sextractor sur ces objets non-elliptiques rencontrent le problème de détections multiples.

3.6 Conclusion

Les galaxies LSB (Low Surface Brightness) sont des objets astronomiques particuliers. En effet, leur faible luminosité les rend difficilement détectable avec les techniques généralement utilisées (seuillage par exemple). Leur étude est cependant primordiale car leur présence pourrait expliquer une partie de la masse baryonique cachée, manquante dans l'univers. De plus, leur analyse apporte beaucoup d'informations sur les processus de formation et d'évolution des galaxies. Les galaxies à faible brillance de surface sont un exemple parfait de l'influence du progrès de la technologie instrumentale puisqu'elles ont pu être détectées grâce à la sensibilité croissante des capteurs CCD. Néanmoins, ces galaxies restent encore difficilement détectables étant donnée que leur brillance de surface est souvent inférieure à la brillance du fond de ciel (limite isophotale). Il est donc nécessaire de proposer un algorithme de recherche de galaxies LSB permettant à l'astronome d'obtenir un ensemble de propriétés pour chaque LSB détectée.

La faible luminosité de ces galaxies induit l'utilisation d'une segmentation statistique qui, en estimant le bruit de l'observation, permet de détecter la distribution de luminosité des objets. La segmentation par quadarbre markovien est donc utilisée dans notre méthode comme une étape préliminaire à la sélection des objets candidats. En effet, chaque objet présent dans la carte de segmentation fait l'objet d'un ensemble d'étapes de sélections morphologiques, dans un premier temps, puis, dans un deuxième temps, d'étapes de construction et de validation de son profil de brillance de surface. Les galaxies LSB répondant à certains critères spécifiques de taille, de luminosité, de forme de profil, notre sélection se base ainsi sur une réalité astronomique. L'obtention d'une ellipse modélisant chacun des objets est, par exemple, réalisée grâce à une hypothèse astronomique (et non mathématique) de symétrie en luminosité.

Les résultats obtenus et présentés dans ce chapitre valident notre approche. En effet, de nombreuses galaxies LSB non détectées par S. Sabatini et Sextractor ont été trouvées par notre algorithme. Cependant, notre méthode de détection est tributaire de la carte de segmentation initiale puisque si l'objet n'est pas présent dans le masque, il ne sera pas traité. Certains objets détectés par S. Sabatini (18 %) ne se retrouvent donc pas dans notre carte de segmentation. Plusieurs approches permettraient de prendre en compte ses objets dans la carte de segmentation :

- seuiller les observations avant la segmentation. En utilisant les résultats de détection des objets brillants obtenus par Sextractor, il est possible d'occulter ces objets lors

du processus de segmentation. Ainsi, l'algorithme markovien répartira ses classes sur des objets faibles uniquement augmentant le nombre d'objets détectés. Cependant, les premières expérimentations ont montré l'apparition d'un phénomène de sur-segmentation (la classe *fond* étant segmentée en 3 ou 4 classes différentes) empêchant l'application directe de notre méthode. En effet les galaxies LSB sont alors entourées d'une multitude de classes différentes et il devient impossible de les séparer de la classe *fond* ;

- segmenter avec un nombre de classes supérieur à 6. Les nouvelles cartes de segmentation obtenues par cette méthode présentent également un phénomène de sur-segmentation, rendant l'application de notre méthode délicate.
- une série de binarisations sur la carte de segmentation pourrait également permettre de sélectionner un nombre plus grand d'objets lors de l'étape de sélection. La première binarisation consisterait à assigner à la classe 1 tous les objets dont la classe est supérieure ou égale à 1, la classe 0 demeurant le fond. Puis une deuxième binarisation conduirait à assigner la classe 0 aux objets de classes 0 et 1 puis la classe 1 aux objets dont la classe est supérieure ou égale à 2, etc.
- raffiner la segmentation en utilisant un nombre de bandes plus élevé dans la segmentation. L'algorithme du quadarbre markovien est utilisable avec des images multibandes. L'approche markovienne multibande va ainsi utiliser simultanément l'information portée par plusieurs bandes. La carte de segmentation résultante peut donc faire apparaître des objets supplémentaires : un objet rayonnant très peu dans une bande peut rayonner fortement dans une autre et être détecté là où il ne l'aurait pas été avec une approche monobande.

L'utilisation d'une approche multibande nécessite un ensemble d'outils facilitant l'interprétation des résultats s'effectuant, cette fois ci, sur une image 3D. Typiquement, comment visualiser simultanément l'information portée sur toutes les bandes de l'observation ? Le chapitre suivant présente deux méthodes de visualisation permettant d'afficher une représentation colorée d'une observation multibande. Cette visualisation offre à l'astronome une vision synthétique et colorée de son cube de données ainsi qu'une facilité d'interprétation de l'observation.

4 Visualisation d'images astronomiques multibandes

4.1 Introduction

La couleur d'un objet astronomique (dans le domaine du visible ou non) correspond à la longueur d'onde dans laquelle son émission est la plus intense. Par exemple, un corps chaud rayonne fortement dans la partie bleue (*i.e.*, vers les longueurs d'ondes courtes) du spectre tandis qu'un corps froid rayonnera plutôt dans le rouge (*i.e.*, vers les longueurs d'ondes élevées par analogie avec la bande optique). L'information de couleur est un paramètre utile au processus d'interprétation des données astronomiques. L'imagerie multispectrale permet, grâce à l'échantillonnage fin de l'information en longueur d'onde, de localiser précisément les raies d'émission et les variations d'intensité du continuum responsables de la couleur d'un l'objet : l'astronome pourra, par exemple, déterminer en étudiant les spectres constituant l'objet si celui-ci est plutôt froid ou chaud ou bien encore mettre en valeur un élément chimique précis dont la raie d'émission se situe dans une partie spécifique du spectre. Cependant, un objet astronomique est rarement de constitution chimique et thermodynamique homogène sur toute sa surface observable : différentes parties de l'objet peuvent rayonner dans différentes longueurs d'ondes. Le travail de l'astronome est donc complexe du fait du grand nombre de spectres à étudier dans l'image multispectrale spatialement résolue (256×256 spectres typiquement). Il est donc nécessaire de proposer des outils de visualisation des images multispectrales astronomiques, par exemple, sous la forme d'une composition colorée interprétable visuellement par l'homme. Ces outils devront permettre, d'une part de visualiser les images en utilisant un espace de couleurs approprié offrant une vision synthétique des données et, d'autre part, d'apporter à l'astronome une aide et une souplesse pour l'interprétation des données multispectrales.

Une première solution, généralement mise en oeuvre pour sa simplicité, consiste à visualiser les bandes spectrales du cube de données sous la forme d'une vidéo. Cependant, sa mise en oeuvre n'est pas toujours possible (support papier par exemple) et l'analyse fine des détails se révèle généralement difficile (la vidéo donnant plutôt une vision globale de l'objet). Une deuxième solution consiste à visualiser l'image multispectrale sous la forme d'une composition colorée dans l'espace RVB (Rouge-Vert-Bleu) où chaque bande paramètre une couleur dans la composition. Dans ce cas, le nombre de bandes est limité à 3 composantes pour une projection directe. Pour les images dont le nombre de bandes c est supérieur à trois, il convient alors de choisir un espace de couleurs approprié ainsi qu'un ensemble de paramètres codant chacun des canaux de l'espace choisi. La composition colorée résultante permet alors de synthétiser l'information présente dans

le cube multispectral sous la forme d'une image couleur unique pouvant être facilement interprétée, diffusée et imprimée. Ce problème de visualisation apparaît également dans d'autres disciplines dès lors que le nombre de bandes de l'observation est supérieur à trois (télédétection, imagerie polarimétrique, imagerie médicale multimodale, etc.) où le modèle que nous proposons pourrait être utilisé. En télédétection, par exemple, P. Scheunders [64] utilise une analyse en composantes principales (ACP) pour visualiser en niveaux de gris des images multispectrales de télédétection. L'approche consiste à découper l'observation multispectrale en plusieurs imagerie (de petites tailles) et à appliquer une ACP locale sur chacune d'elle. L'ACP locale projette les observations multispectrales de chaque imagerie dans un nouvel espace défini par les vecteurs propres de la matrice de covariance Σ estimée localement. Cette technique ne donne généralement pas de résultats très probants en imagerie astronomique, où les frontières entre objets sont assez floues (pas de contours nets), la dynamique importante et les objets de tailles différentes [70]. Dans [45], les auteurs proposent une méthode de visualisation d'images hyperspectrales de télédétection : pour un spectre donné, sa couleur dans la composition colorée (dans l'espace RVB) est donnée par une combinaison linéaire entre les valeurs de réflectances et un ensemble de coefficients r , g et b nommés *enveloppes spectrales*. En d'autres termes, chaque spectre de l'observation est projeté sur une base composée de trois spectres : r , g et b . Le choix de ces trois spectres est libre et peut être déduit des travaux de la CIE (Commission Internationale de l'Éclairage) ou bien correspondre aux trois premières composantes principales issues d'une ACP. D'autres approches consistent à augmenter le contraste des différents éléments d'une image : par exemple dans [50], une technique d'égalisation d'histogramme couleur est proposée pour réhausser le contraste de l'image couleur. Dans [71] une nouvelle méthode statistique d'égalisation d'histogramme pour les images RVB est développée mais ces méthodes nécessitent une composition colorée préalable et n'ont pas été développées dans l'optique d'offrir une représentation synthétique des données.

L'approche retenue ici consiste à utiliser la carte de segmentation de l'image multispectrale, obtenue sur le quadarbre markovien [15], afin de dégager des informations propres aux classes et de les transcrire dans la composition colorée. L'utilisation de l'approche markovienne est inadaptée si le nombre de bandes de l'observation est supérieur à 10 (malédiction de la dimensionnalité). Dans ce cas, il est nécessaire de réduire au préalable l'observation à l'aide d'une approche de regroupement de bandes [25] présentée dans ce chapitre.

La première partie de ce chapitre introduit la notion d'espace de couleurs nécessaire à la visualisation colorée d'images astronomiques et détaille notamment les espaces de couleurs répandus (RVB et TSL, Teinte Saturation Luminance). La partie suivante introduit l'algorithme de réduction de données mis en place, dans le cas où $c > 10$ ainsi que l'analyse factorielle discriminante permettant de répartir les classes dans l'espace de couleurs, utilisée dans notre méthode de visualisation. Une troisième partie présente une première méthode de visualisation colorée où les trois canaux de l'espace de couleurs sont paramétrés par une analyse en composantes principales ainsi que par les deux premiers axes d'une analyse factorielle discriminante. Des résultats sur quelques images astronomiques multibandes (6 bandes) et superspectrales (48 bandes) sont également présentés, ainsi qu'un résultat sur une image issue du domaine de la télédétection (6 bandes). La quatrième partie introduit une deuxième méthode de visualisation colorée prenant mieux en compte, dans la représentation colorée, la notion de couleur astronomique par une

analyse locale de chacun des spectres de l'observation. Cette méthode sera cependant difficilement applicable lorsque $c > 10$ étant donné que l'étape de réduction de données supprime une partie de l'information spectrale (position des raies d'émission par exemple). Des résultats sur quelques images astronomiques seront également présentés puis comparés avec les résultats obtenus avec la première méthode.

4.2 Notations utilisées

Notation	Signification
Y	Observation
c	Nombre de bandes de l'observation
N	Nombre de pixels dans l'observation
s	Site de l'observation
ω_k	Classe k
K	Nombre de classes
J_k	Ensemble des pixels de l'observation appartenant à la classe ω_k
$\mathcal{T}, \mathcal{W}, \mathcal{B}$	Matrice totale, intra-classe et inter-classes de l'AFD
\sharp	Cardinal
\mathcal{E}	Vecteurs propres de l'AFD
Ξ	Valeurs propres de l'AFD
τ_s	Indice de couleur

4.3 Colorimétrie

Un espace de couleurs est un espace de dimension 3 où chaque point définit une couleur en fonction de la paramétrisation de chacun des trois axes. La compréhension de la perception de la couleur est une problématique complexe, en constante évolution, à la frontière de plusieurs disciplines. Physiologiquement, la perception de la couleur par l'oeil humain [43] fait intervenir deux types de cellules :

- les cônes sont des cellules de la rétine permettant d'interpréter la couleur. Ils sont de trois types selon leur sensibilité au bleu, vert ou rouge. Leur sensibilité à une de ces couleurs est due à la présence de pigments absorbant la lumière selon les longueurs d'ondes courtes, moyennes ou longues. Ils sont au nombre de 5 millions environ ;
- les bâtonnets sont spécialisés dans la vision à faible éclairage. Ils ne permettent pas de vision colorée (tous les objets paraissent gris la nuit) et sont inadaptés à la détection des contours.

La manipulation de la couleur passe tout d'abord par la définition d'un espace paramétrique permettant une représentation de la couleur appropriée. Cet espace peut s'appuyer sur des grandeurs physiques, physiologiques, mathématiques [72]. L'espace RVB est, par exemple, utilisé dans le domaine de l'informatique et du multimédia tandis que l'espace CMYK (Cyan, Magenta, Yellow, Black), complémentaire de l'espace RVB, est utilisé en imprimerie pour des raisons pratiques [76]. De nombreux espaces de couleurs se basent également sur la perception de la couleur par l'oeil humain (développés, par exemple, par la Commission Internationale de l'Eclairage - CIE). C'est le cas de l'espace XYZ élaboré en mesurant un ensemble de statistiques sur un très grand nombre de personnes. Ainsi à

chaque couleur perçue correspond une coordonnée dans l'espace XYZ.

L'espace Lab est issu de l'espace XYZ. Il essaye de prendre en compte la réponse logarithmique de l'oeil. Contrairement à l'espace XYZ où chaque couleur est définie par une coordonnée (X, Y) , Z correspondant à la profondeur donc à la luminosité de chaque couleur, l'espace Lab définit une couleur par sa luminosité L (de 0 à 100), a pour la couleur du rouge au vert et b pour la couleur du bleu au jaune (-128 à $+128$). Il est très utile dans le cas de mélanges de pigments, par exemple, pour l'industrie graphique ou du textile.

L'espace YUV est un espace colorimétrique utilisé dans les systèmes de diffusion télévisuelle PAL et NTSC. La composante Y correspond à la luminance (niveau de luminosité) tandis que les composantes U (différence de rouge, écart entre le niveau de rouge et la luminance) et V (différence de bleu, écart entre le niveau de bleu et la luminance) correspondent à la chrominance (information de couleur). L'espace YDbDr, dérivé de l'espace YUV est utilisé par le système SECAM. Les composantes Db et Dr sont les différences de couleur bleu et rouge. L'espace YUV est plus proche de la perception humaine que l'espace RVB mais ne la décrit pas autant que l'espace TSL et ses dérivés.

L'espace TSL (ou HSV en langue anglaise : Hue Saturation Value) et ses variantes (HSL (Luminance), HSI (Intensity)) sont basés sur la perception physiologique de la couleur par l'oeil humain, en introduisant des notions de Teinte ("Hue"), Saturation ("Saturation") et de Luminance ou Intensité ("Value"). De nombreux travaux ont été menés pour mettre au point de nouveaux espaces de représentation des couleurs pour des utilisations et des contraintes bien particulières, notamment dans le domaine de la vidéo [7], de la robotique [37], de la synthèse d'image [12] et de la reconnaissance d'objets [31]. Les espaces RVB et TSL, fréquemment utilisés dans la manipulation des couleurs sont détaillés dans les deux sections suivantes.

4.3.1 L'espace RVB

Le modèle RVB demeure l'espace coloré le plus répandu. En effet, il est utilisé dans la plupart des outils matériels de visualisation (écran, vidéoprojection...). Dans cet espace, chaque couleur est définie par trois composantes : Rouge, Vert et Bleu à valeurs à l'intérieur d'un cube unité (fig. 4.1.a). Cet espace a été développé en fonction des connaissances liées à la vision humaine, les cônes de la rétine humaine étant plus sensibles à ces trois couleurs. Le modèle RVB est un modèle additif, *i.e.*, chaque couleur est déduite à partir du noir ($R = V = B = 0$) en ajoutant plus ou moins certaines composantes (fig. 4.1.b). Son complémentaire (l'espace CMYK) est un modèle soustractif dans lequel les couleurs sont définies à partir du blanc. Il est principalement utilisé dans les travaux d'imprimerie (imprimerie quadrichromique). Ainsi, l'obtention d'une couleur dans l'espace CMYK s'effectue par la soustraction des composantes C , M et Y (on parle alors de synthèse soustractive, contrairement à la synthèse additive de l'espace RVB). La composante K (noire) est utilisée pour obtenir les couleurs grises, difficiles à synthétiser à l'aide des trois composantes primaires CMY. L'ajout du noir permet aussi de mieux contraster les images et de produire des textes plus nets. Le noir étant une couleur moins coûteuse à fabriquer que les autres teintes, son utilité est non seulement d'ordre esthétique mais également économique. Le principal inconvénient de l'espace RVB réside dans la manipulation quelque fois complexe des couleurs. En effet, l'augmentation de la luminosité

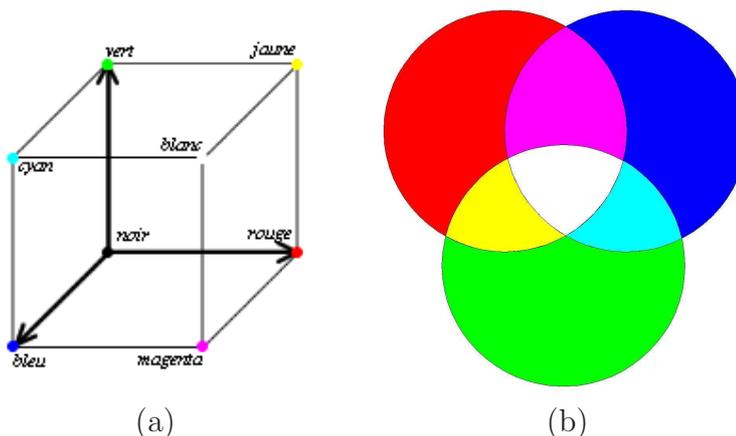


FIG. 4.1 – (a) : Cube RVB. (b) : Composition additive des couleurs

d'une couleur s'effectue en variant proportionnellement les trois composantes. Les trois canaux R, V et B sont donc fortement corrélés. Cette contrainte majeure de manipulation rend l'espace RVB inapproprié pour la visualisation que nous souhaitons réaliser. Par ailleurs, les règles d'interprétations de mélanges colorés (*i.e.*, vert=jaune+ bleu) héritées des conventions artistiques ne s'appliquent pas directement dans l'espace RVB, d'où une difficulté d'interprétation. Il s'avère donc préférable pour nos opérations sur les observations astronomiques multibandes, d'utiliser le modèle psychovisuel TSL basé sur la perception de la couleur par l'oeil.

4.3.2 L'espace TSL

L'espace colorimétrique TSL (Teinte, Saturation, Luminance) a été développé pour offrir une manipulation intuitive des couleurs et permettre une sélection manuelle facile dans les applications interactives de type PAO. Il permet de décomposer une couleur en trois critères physiologiques :

- la teinte qui correspond à la perception de la couleur, $0 \leq T \leq 360$;
- la saturation qui correspond à la pureté de la couleur (vif ou terne), $0 \leq S \leq 1$;
- la luminance correspondant à la quantité de lumière de la couleur (clair ou sombre), $0 \leq L \leq 1$.

Ces trois composantes définissent un cône représenté dans la fig. 4.2.a où l'ensemble des couleurs représentables est également synthétisé (fig. 4.2.b). Chaque composante étant reliée à une perception physiologique intuitive, la manipulation des couleurs dans l'espace TSL est intuitive et souple puisque contrairement au modèle RVB où les composantes sont corrélées, par exemple, l'augmentation de la luminosité d'une couleur se fait uniquement en incrémentant la valeur sur l'axe de la luminosité et sa saturation dépend de la distance à l'axe central du cône. Ce sont des propriétés essentielles pour le maniement de la couleur. L'espace de représentation des couleurs TSL a donc été retenu dans nos méthodes de visualisation d'images astronomiques multispectrales.

Les deux méthodes de visualisation proposées ci-après utilisent une analyse factorielle discriminante afin de paramétrer certains canaux de l'espace TSL ainsi qu'une étape préliminaire de réduction basée sur une analyse en composantes principales si le nombre

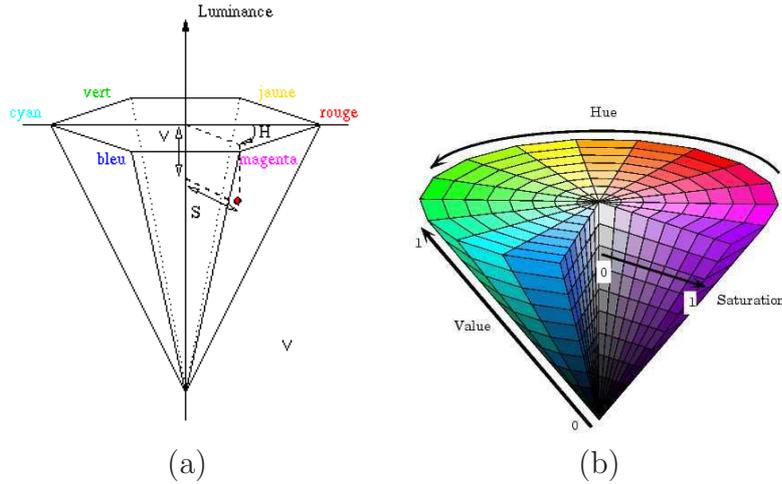


FIG. 4.2 – (a) : Cône TSL. (b) : Ensemble des couleurs de l'espace TSL

de bandes de l'observation est supérieur à 10. Ces deux méthodes sont détaillées dans la partie suivante.

4.4 Réduction et analyse de données

Les méthodes de réduction et d'analyse de données permettent de synthétiser un ensemble réduit de valeurs tout en cherchant à conserver le maximum d'informations présentes dans les observations originales. Notre problématique étant de fournir une représentation synthétique des observations sous la forme d'une composition colorée, une méthode d'analyse de données (l'analyse factorielle discriminante) est étudiée. Une réduction étant nécessaire lorsque $c > 10$, une méthode basée sur un algorithme de coalescences est également présentée.

4.4.1 L'analyse factorielle discriminante

L'analyse factorielle discriminante (AFD [74]) est une méthode classique d'analyse de données supervisée qui permet la projection des données dans un espace maximisant la variance inter-classes tout en minimisant la variance intra-classe. L'utilisation de ces deux critères permet de déterminer les axes de projection séparant linéairement les classes.

Soit $Y = (y_1, \dots, y_b)$ les observations avec c le nombre de bandes et N le nombre de pixels de chaque image. Chaque site s de Y est associé à une classe ω_k avec $k \in \{1..K\}$. L'ensemble des sites s de la carte de segmentation X appartenant à ω_k est noté J_k . On peut alors représenter Y sous forme matricielle en adoptant les conventions de notation précisées dans la fig. 4.3.

L'AFD consiste à calculer trois matrices de covariance :

- \mathcal{T} (total) : matrice totale de covariance (éq. (4.2)) ;
- \mathcal{B} (between) : matrice de covariance inter-classes (éq. (4.3)) ;
- \mathcal{W} (within) : matrice de covariance intra-classes (éq. (4.4)) ;

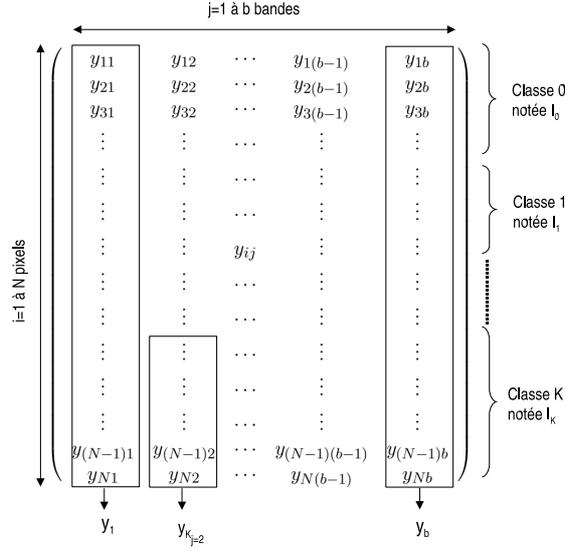


FIG. 4.3 – Représentation matricielle des observations. Le vecteur y_j représente la bande j de Y mise sous la forme d'un vecteur colonne. y_{k_j} correspond aux sites de la bande j appartenant à la classe ω_k .

Ces trois matrices vérifient la propriété [74] :

$$\mathcal{T} = \mathcal{W} + \mathcal{B} \quad (4.1)$$

avec

$$t_{jj'} = \frac{1}{N} \sum_{i=1}^N (y_{ij} - \bar{y}_j)(y_{ij'} - \bar{y}_{j'}) \quad (4.2)$$

et

$$b_{jj'} = \sum_{k=1}^K \frac{\#J_k}{N} (\bar{y}_{kj} - \bar{y}_j)(\bar{y}_{kj'} - \bar{y}_{j'}) \quad (4.3)$$

et

$$w_{jj'} = \frac{1}{N} \sum_{k=1}^K \sum_{j \in J_k} (y_{kj} - \bar{y}_{kj})(y_{kj'} - \bar{y}_{kj'}) \quad (4.4)$$

où \bar{y}_j est la moyenne de la bande j :

$$\bar{y}_j = \frac{1}{N} \sum_{i=1}^N y_{ij} \quad (4.5)$$

et \bar{y}_{kj} est la moyenne de la bande j pour tous les sites s appartenant à la classe ω_k :

$$\bar{y}_{kj} = \frac{1}{\#J_k} \sum_{i=1}^{\#J_k} y_{ij} \quad (4.6)$$

et $\#J_k$ désigne le cardinal de l'ensemble J_k .

On montre alors que les axes de projection donnés par les vecteurs propres $\mathcal{E} \in \{\mathcal{E}_1 \dots \mathcal{E}_N\}$ de $\mathcal{T}^{-1}\mathcal{B}$ vérifient [74] :

$$\mathcal{T}^{-1}\mathcal{B}\mathcal{E}_i = \Xi_i\mathcal{E}_i \quad (4.7)$$

On supposera par la suite que les vecteurs propres sont ordonnés par valeurs propres décroissantes. Les observations sont ensuite projetées sur cette base de vecteurs propres et seules les n premières images résultantes, correspondantes aux n valeurs propres les plus grandes, sont conservées. On obtient donc les images projetées z_l de la manière suivante :

$$z_l \propto \sum_{j=1}^N y_{lj} \times \mathcal{E}_l(j) \quad (4.8)$$

$\mathcal{E}_l(j)$ étant la composante j du vecteur propre associé à la l -ième plus grande valeur propre.

Il convient de noter, d'une manière générale, qu'il suffit de $k - 1$ axes pour séparer k classes.

Notre méthode de visualisation des images astronomiques multispectrales cherche à transcrire dans la composition colorée, les variations de luminance intra-classes. L'analyse factorielle discriminante permet de réaliser ceci au travers des critères de maximisation de la variance intra-classes et de minimisation de la variance inter-classe.

4.4.2 Réduction des données

Les méthodes de réduction de données sont généralement utilisées lorsqu'intervient le phénomène de malédiction de la dimensionnalité. Le travail dans un espace réduit permet de faciliter les traitements postérieurs dans un espace de dimension bien inférieure à la dimension de l'espace originale.

Les méthodes ACP et ACI, dérivées des méthodes de poursuites de projection, projetant les données dans un espace maximisant un certain critère, sont généralement utilisées pour leur simplicité. Cependant, la projection résultante peut être difficilement interprétable et l'espace obtenu de manipulation peu intuitive. Les méthodes d'approximation de spectres par mélange de lois gaussiennes[24] permettent de représenter un spectre sous la forme d'une combinaison linéaire de lois gaussiennes. Dans [24], l'estimation des paramètres du mélange de lois se fait grâce à l'algorithme EM. Ces méthodes restent peu applicables dans le cas de grands cubes de données présentant de nombreuses raies d'émission/absorption.

Lorsque le nombre de bandes dépasse la dizaine, nous adoptons au préalable une stratégie de regroupement de bandes utilisant un algorithme de "bottom up clustering" avec une mesure de similarité multiéchelles [14, 25]. L'approche consiste à supposer que les bandes dont les longueurs d'ondes sont proches, sont généralement très corrélées et leur apport d'informations est redondant. La méthode se décompose alors en deux phases :

- regroupement des bandes en *cluster* en fonction d'un critère de similarité ;
- projection dans chacun des *clusters* à l'aide d'une ACP ou d'une ACI.

L'algorithme utilisé consiste à grouper les bandes deux par deux au fur et à mesure des itérations en fonction d'une mesure de similarité multirésolution basée sur les histogrammes normalisés[13] combinés avec les moments d'inertie d'ordre 1 (barycentre). Soit

h_i^k l'histogramme normalisé d'une image i à l'échelle k , alors la mesure de divergence à l'échelle k est : $D_{ij}^k = (h_i^k - h_j^k) \log \frac{h_i^k}{h_j^k}$. On pose g_i^k comme étant le barycentre de l'image i à l'échelle k . On note alors l_{ij}^k comme la distance euclidienne entre les deux barycentres g_i^k et g_j^k . En sommant tous les barycentres et toutes les divergences à toutes les échelles, on obtient alors une mesure de similarité entre deux images i et j . Cette mesure est alors utilisée pour grouper les bandes deux à deux.

L'utilisateur fournit, en entrée de l'algorithme, le nombre de bandes réduites voulues, correspondant ainsi au nombre de *clusters* à construire.

La réduction au sein de chaque sous-ensemble est alors réalisée par une ACP ou une ACI (algorithme FastICA avec décorrélation déflationniste [35])

4.5 Première méthode de visualisation colorée

L'utilisation de la carte de segmentation, obtenue à l'aide d'une approche markovienne non supervisée [51, 40] au sens des critères MAP (*Maximum a Posteriori*) ou MPM (*Marginal Posterior Modes*) va permettre de dégager des zones pertinentes dans les observations et de les associer en classes afin d'utiliser les informations de chacune d'entre elles pour paramétrer chaque canal de l'espace de couleurs. La visualisation des images multibandes passe alors par quatre étapes :

1. la première consiste à effectuer éventuellement une réduction du nombre de bandes si $c > 10$. Les images ainsi réduites alimentent un classifieur markovien hiérarchique défini sur une structure de type quadarbre[52]. Cette stratégie a été validée sur des images de synthèse et testée sur images astronomiques [25]. Si le nombre de bandes est inférieur à la dizaine, cette étape de réduction de données n'est plus nécessaire puisque le classifieur markovien utilisé pour obtenir la carte de segmentation supporte jusqu'à une dizaine de bandes en entrée ;
2. une deuxième étape consiste à employer une méthode de coalescences (regroupements) pour apparier la carte de segmentation à l'observation (ou aux bandes réduites si nécessaire) à l'aide d'une analyse factorielle discriminante [74], afin d'aboutir aux deux canaux T et S, et d'une analyse en composantes principales pour le canal L. Les classes seront alors distribuées sur le cercle T, S en fonction des critères de l'AFD, *i.e.*, les classes seront éloignées les unes des autres sur le cercle T, S (maximisation de la variance inter-classes) et les pixels d'une même classe seront regroupés de manière compacte (minimisation de la variance intra-classe), *cf.* section 4.5.2 pour l'AFD et section 4.5.1 pour l'ACP ;
3. la troisième étape effectue la composition colorée de ces 3 bandes dans un espace de couleurs TSL ;
4. la dernière étape consiste à convertir l'image TSL en une image dans l'espace RVB pour la simplicité d'affichage. Chaque triplet TSL est ainsi convertit en triplet RVB. Ainsi l'image RVB retranscrit les variations de teinte, saturation et luminance propre aux transformations effectuées dans l'espace TSL sur les observations. L'image peut alors être affichée sur un écran.

Lors de l'affichage à l'écran de la composition colorée, celle-ci est convertie dans l'espace RVB. Cette conversion [76] s'effectuera selon l'algorithme détaillé ci-après. Une simple af-

fectation des canaux TSL aux canaux RVB ne suffit pas. En effet l'utilisation de l'espace TSL permet de mettre en valeur des changements de contrastes, de teintes et de luminosités. Ainsi, en affectant le canal T au canal R par exemple, la variation de teinte se traduirait alors par une variation de la couleur rouge (idem pour la saturation et la luminosité) ce qui ne correspond pas aux variations attendues dans la composition colorée. La figure 4.4 résume toutes les étapes du processus de visualisation des images multibandes astronomiques.

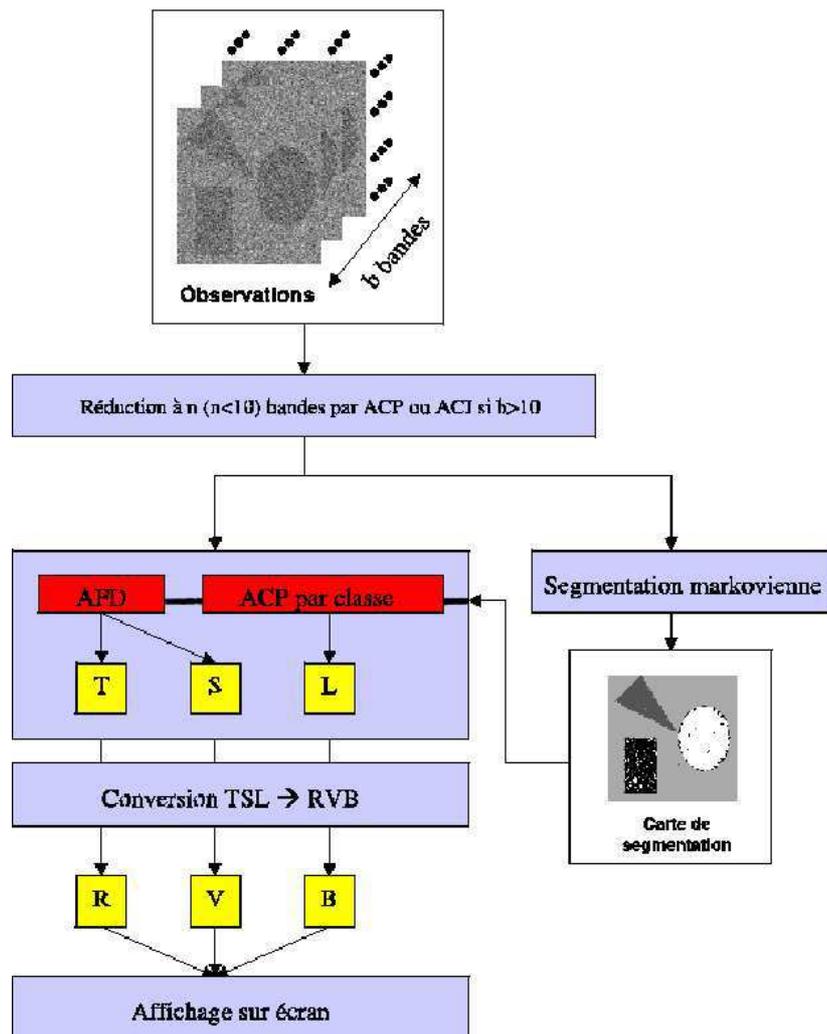


FIG. 4.4 – Méthode de visualisation de cubes de données multicomposantes. L'originalité de l'approche réside dans l'utilisation d'une carte de segmentation qui est utilisée comme *a priori* dans la modélisation couleur TSL. Cette approche est générale et susceptible de s'appliquer à d'autres disciplines confrontées au délicat problème de visualisation de données multivariées.

4.5.1 Utilisation de l'ACP pour l'axe L

La prise en compte de l'information portée par la carte de segmentation X va permettre d'effectuer une ACP locale dans chaque classe ω_k et obtenir ainsi une base de vecteurs propres associée à un ensemble de valeurs propres pour chaque classe. Une première possibilité dans la visualisation consiste à retenir les 3 premières images projetées pour effectuer une composition colorée dans l'espace TSL. Mais l'ACP est une méthode de décorrélation inter-bandes spectrales maximisant la variance des données. Ainsi, si les variances dans chaque classe sont proches, mal estimées ou si le bruit prédomine, l'ACP ne séparera pas les classes entre elles et le résultat de la composition sera difficilement interprétable. On peut néanmoins envisager de placer les classes sur l'axe L (du noir au blanc en passant par les niveaux de gris) de l'espace TSL en utilisant l'ensemble des valeurs propres issues de l'ACP, cet ensemble représentant l'énergie totale contenue dans l'image. Le calcul du pourcentage d'énergie porté par la plus grande valeur propre de chaque classe positionnera celles-ci sur l'axe L. Ainsi, plus la variance d'une classe sera élevée (relativement aux autres classes), plus son positionnement sur l'axe L sera proche de 1 (blanc). A contrario, si deux classes ont la même variance, la distinction entre elles s'effectuera au niveau des axes T et S de l'espace TSL à l'aide d'une analyse factorielle discriminante présentée dans le paragraphe suivant. Chaque classe possède donc une luminosité fixée sur l'axe L, ainsi l'ensemble des valeurs que pourront prendre les pixels de cette classe sont disposées dans l'espace TSL sur un disque dont le rayon croît avec la variance de la classe, garantissant une certaine hétérogénéité (liée à la teinte et à la saturation) intra-classe dans la composition colorée.

4.5.2 Utilisation de l'AFD pour les axes T et S

Notre but, dans la visualisation des images multibandes est de maximiser le contraste entre les classes (variance inter-classes) tout en traduisant la variance interne à chaque classe (intra-classe). Cette approche permet d'une part d'assigner à chaque classe une teinte générale et d'autre part de retranscrire à l'intérieur de chaque classe les variations de luminances présentes dans le cube des observations. Les classes seront "éloignées" les unes des autres sur l'axe T et l'axe S, tandis que les pixels appartenant à la même classe tenderont à être proches sur ces mêmes axes. L'analyse factorielle discriminante introduite précédemment, permet d'obtenir les plans T et S de la composition colorée en ne gardant que les deux premiers vecteurs propres (éq. (4.9)) :

$$T \propto \sum_{j=1}^N y_{ij} \times \mathcal{E}_1(j) \text{ et } S \propto \sum_{j=1}^N y_{ij} \times \mathcal{E}_2(j) \quad (4.9)$$

Les images étant ensuite visualisées sur un écran d'ordinateur, il est nécessaire de convertir les données TSL en données RVB [76] (algorithme ci-dessous).

$$\begin{cases} J = L \times (1 - S) \\ K = L \times (1 - S \times F) \\ U = L \times (1 - S \times (1 - F)) \end{cases} \quad (4.10)$$

Algorithme 4.1 : Conversion RVB vers TSL et opération inverse

Entrée: | R, V, B : Canaux R, V et B de l'image couleur

- $T = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-V)+(R-B)]}{\sqrt{(R-V)^2+(R-B)(V-B)}} \right\}$
- $S = \frac{\max(R,V,B) - \min(R,V,B)}{\max(R,V,B)}$
- $L = \max(R, V, B)$

Entrée: | T, S, L : Canaux T, S et L de l'image couleur

Si $L = 0$ **Alors**

- $R = V = B = 0$

Sinon

- $C = \frac{T}{60}$ (division entière), C est donc la couleur générale du pixel considéré ($C \in [0...5]$)
- $F = \frac{T-60 \times C}{60}$ est la partie fractionnaire du rapport $\frac{T}{60}$
- On déduit alors les trois valeurs J, K et U (éq. (4.10))
- Ces résultats conduisent aux composantes RVB selon la valeur de C à l'aide du tableau (4.1)

Fin Si

C	R	V	B
0	L	U	J
1	K	L	J
2	J	L	U
3	J	K	L
4	U	J	L
5	L	J	K

TAB. 4.1 – Matrice de conversion TSL vers RVB en fonction de C [76]

4.5.3 Résultat sur une image simple

L'image présentée dans la fig. 4.5.a est composée de 3 bandes (bande R, V et B). Elle a été segmentée en 8 classes (fig. 4.5.b) par l'algorithme markovien. Le résultat obtenu après ACP et AFD (fig. 4.6.a) est la composition colorée dans l'espace TSL des 3 bandes de départ :

- chaque classe est répartie relativement sur l'axe L en fonction de la plus grande valeur propre obtenue par ACP ;
- les 3 bandes sont projetées sur les deux vecteurs propres correspondant aux deux plus grandes valeurs propres de l'AFD et affectées aux axes T et S de chaque classe (pour les bandes T,S).

Les figures 4.6.b,c,d correspondent respectivement aux trois plans T, S, L.

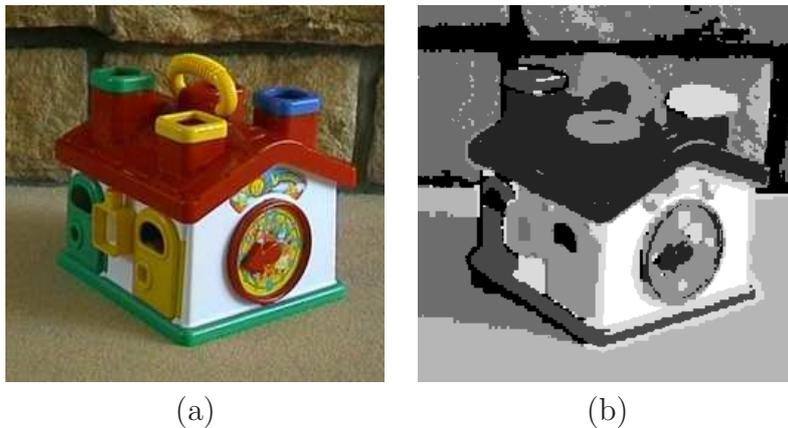


FIG. 4.5 – (a) : Image originale (3 bandes RVB), taille : 256×256 pixels. (b) : Carte de segmentation markovienne en 8 classes

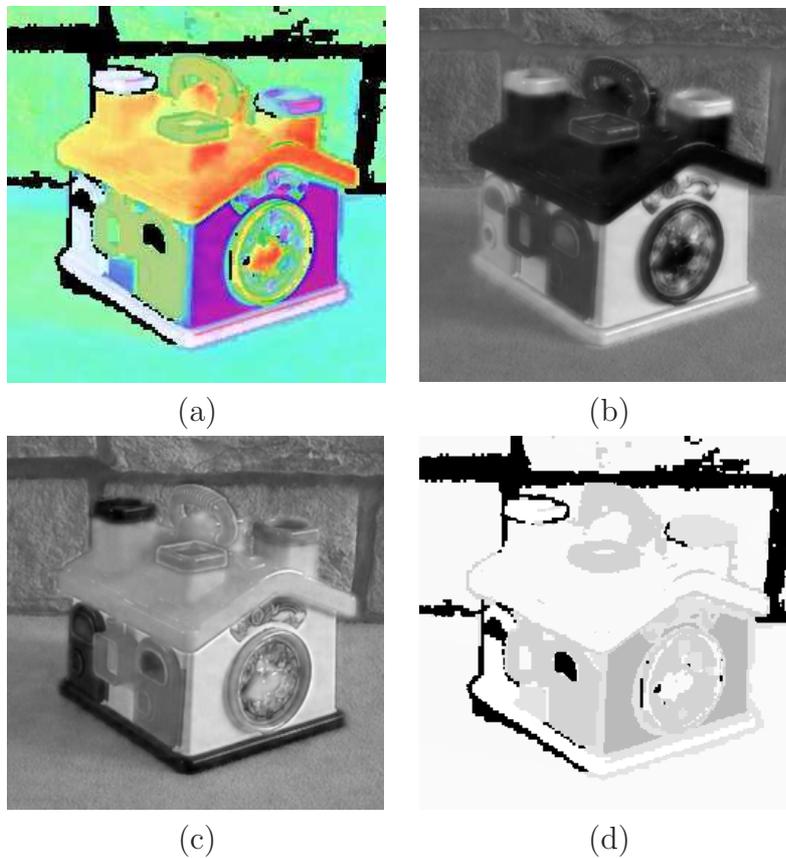


FIG. 4.6 – (a) : Composition TSL. (b) : Canal T. (c) : Canal S. (d) : Canal L. Le résultat obtenu est cohérent avec l'observation. Les effets d'ombrage et de contraste ont été conservés dans la composition colorée, notamment sur l'avant du toit de la maison et sur l'ombre de la maison sur le sol, sur la gauche de l'image. Une classe donnée possède la même luminance mais des saturations et des teintes différentes dans ce mode de représentation. La méthode présentée permet de discriminer les pixels entre eux en soulignant leurs similitudes et leurs différences de comportements spectraux. La teinte assignée à une classe reste arbitraire. Lorsqu'un ensemble de pixels a une teinte identique dans la composition, cela signifie que tous les pixels de cet ensemble ont le même comportement spectral dans les observations. Ainsi dans la figure 4.6.a, les pixels ayant la même teinte ont été identifiés comme ayant le même comportement spectral dans les trois bandes originales. Ce processus d'interprétation est le même dans le cas d'observations, astronomiques ou issues de la télédétection (voir section suivante).

4.5.4 Résultats sur des images obtenues en télédétection

Pour montrer la généralité de l'approche, ce processus de représentation a été premièrement testé sur un jeu d'images de télédétection aérienne. Il s'agit de 6 bandes (choisies par un expert) issues d'un cube hyperspectral de 128 bandes obtenu par le capteur HyMap à une résolution au sol de 4m (fig. 4.7). Cette image représente la forêt de Hartheim, deux canaux, un village, une route ainsi que des zones de cultures. La carte de segmentation comporte quatre classes (fig. 4.8.a). La composition colorée résultante est présentée figure 4.8.b.

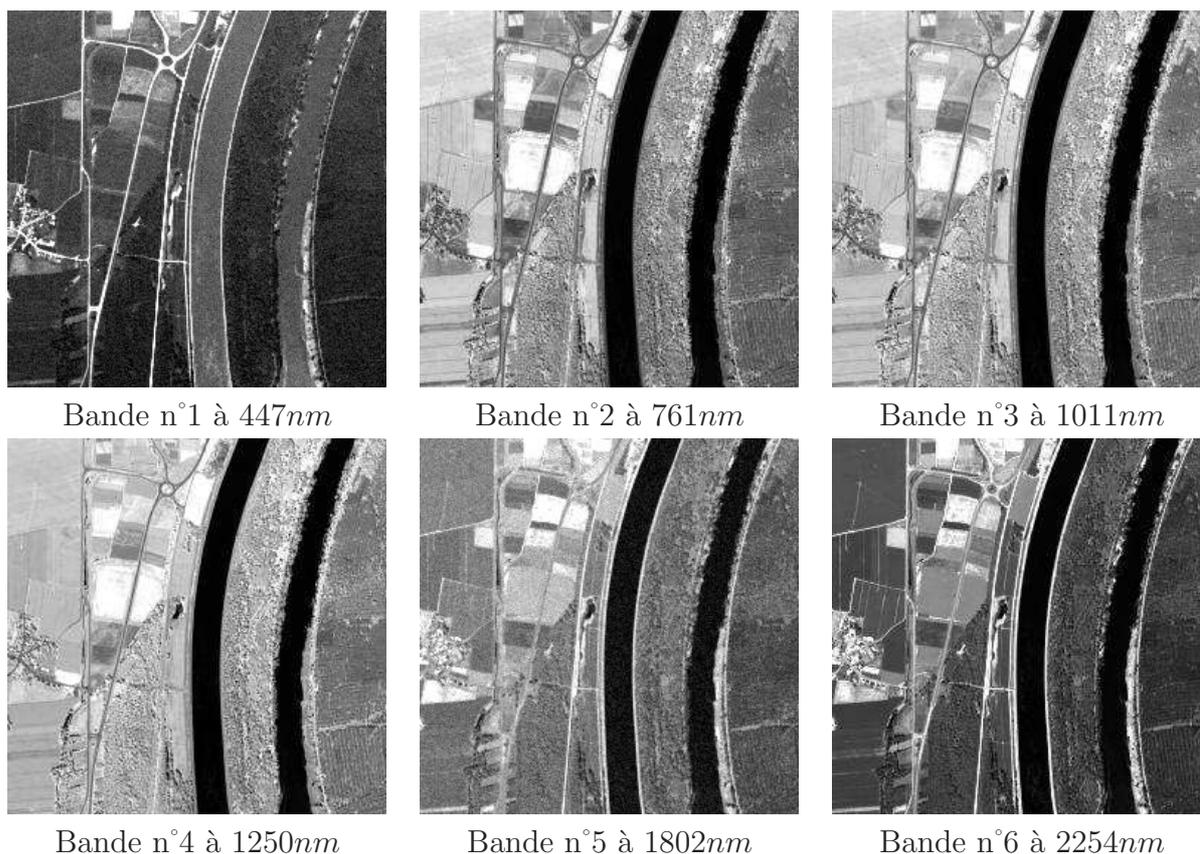


FIG. 4.7 – Télédétection aérienne : 6 bandes extraites d'un cube de données prises au dessus de la forêt de Hartheim à l'aide du capteur hyperspectral HyMap (128 canaux), à une résolution de 4m au sol . On y observe le Rhin, une zone de forêt à droite, le réseau routier avec un rond point en haut, des champs et une zone d'habitation (village). Taille : 378×378 pixels. Nous remercions J. Label-Nachbrand (LSIIT, Equipe TRIO, UMR CNRS 7005, STRASBOURG) pour la mise à disposition de ces images.

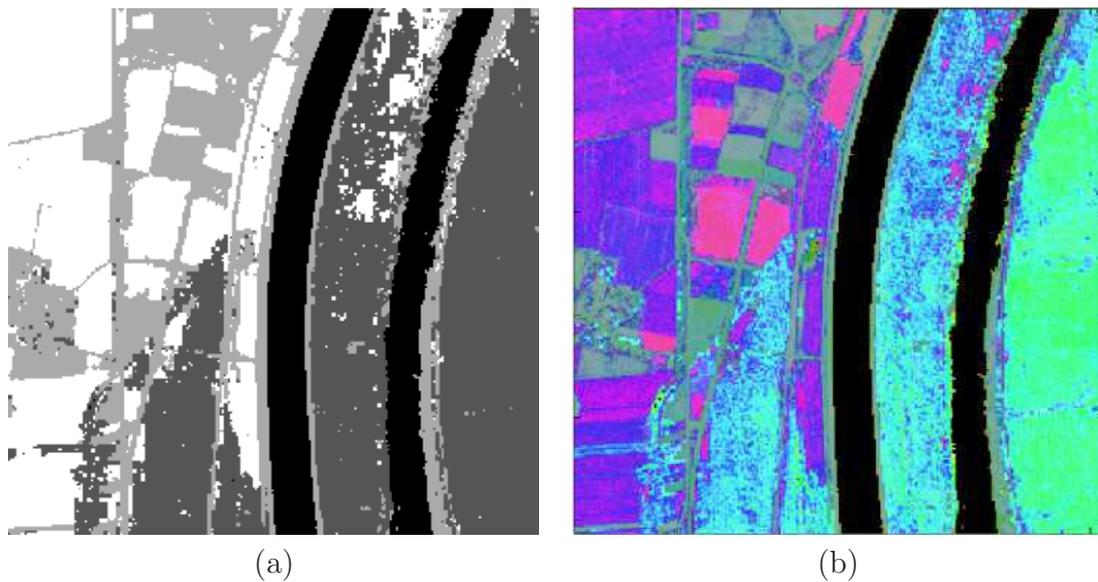


FIG. 4.8 – (a) : Carte de segmentation en 4 classes de la forêt de Hartheim. (b) : Composition colorée TSL obtenue. L'image (b) permet d'extraire toutes les caractéristiques et les informations présentes dans les 6 bandes originales. En effet, la forêt, la route, le village, les canaux (ici considérés comme la classe de luminosité minimale et affichés en noir) et les champs sont bien discriminés. La variance interne à chaque classe est mise en évidence par de faibles variations de teintes : violet-fuchsia pour une classe "champs" bleu-vert pâles pour la classe "forêt".

4.5.5 Résultats sur des images astronomiques

Dans le processus d'interprétation des images astronomiques, l'astronome se concentre sur la détection des objets et cherche à en mesurer la position, la luminosité ainsi que certains paramètres morphologiques : surfaces, etc... Lorsque l'on analyse une image monobande, une visualisation en niveaux de gris, permet d'interpréter facilement la scène, l'œil humain étant sensible à la luminance des objets. Si l'astronome choisit d'analyser simultanément plusieurs bandes (fig. 4.9), il va chercher à interpréter les similitudes et les différences entre les différents canaux.

L'analyse approfondie vise à identifier les différents processus physiques ou régions par leur signature spectrale individuelle. Dans la visualisation proposée ici, on construit une vue résumée du comportement multispectral d'un pixel. L'ACP permet de répartir les classes sur l'axe des luminances tandis que l'AFD permet d'optimiser la différenciation des classes entre elles et des pixels appartenant à une même classe. Dans les exemples suivants, le rôle du masque fourni par la segmentation markovienne [40] est d'identifier les principaux comportements spectraux dans des classes assez générales. La variation des pixels dans chaque classe pourra être ensuite représentée sur le cercle T, S.

Le fond (milieu interstellaire) dans les images astronomiques occupe généralement une majeure partie de l'image. Pour occulter celui-ci, qui n'apporte pas d'informations particulières, la valeur sur la composante L de la classe identifiée comme fond (norme du vecteur moyenne $\mu_k = (\mu_{k1}, \dots, \mu_{kN})$ la plus faible, où μ_{ki} est la moyenne de la classe k dans la bande i) est mise à 0. Ainsi, quelles que soient les valeurs dans les plans T et S, le fond restera noir. Tous les résultats obtenus sur les images astronomiques ont été validés par plusieurs astronomes.

4.5.5.1 Résultats sur ORION

On étudie ici un jeu d'images de la zone d'Orion (fig. 4.9), issu de la mission 2MASS, sur 3 bandes : J (1.2 - 1.4 microns), H (1.5 - 1.8 microns), K (2 - 2.4 microns).

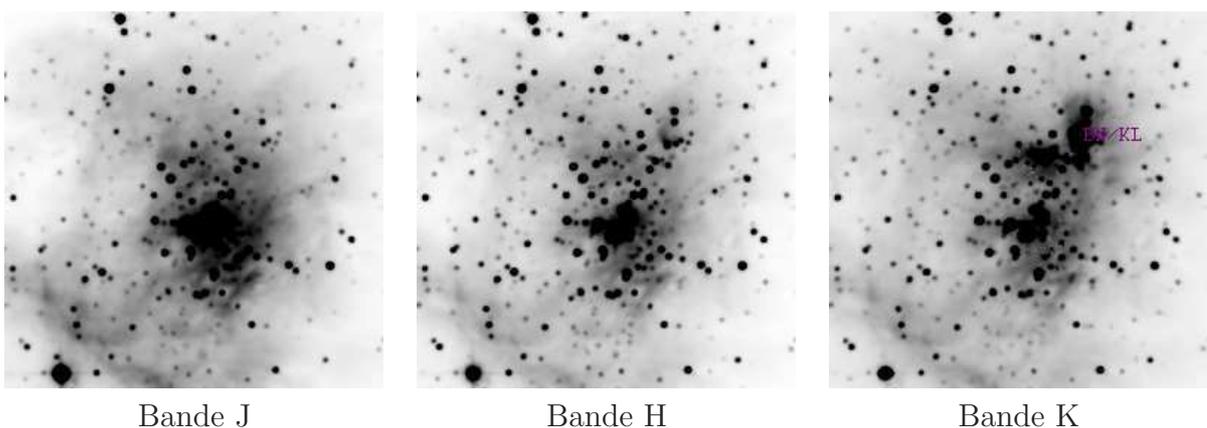


FIG. 4.9 – ORION : 3 images 2MASS. Taille : 256×256 pixels.

Pour visualiser une composition colorée directe, on peut associer les bandes J, H et K aux 3 canaux R, V et B respectivement (fig. 4.10). On met ainsi en évidence les

contributions différentes des 3 bandes : nuage dense en haut a droite (bande K), nébuleuse diffuse autour de la zone centrale (bande J).



FIG. 4.10 – ORION : Composition colorée dans l'espace RVB. Cette méthode présente un intérêt cosmétique évident mais ne s'applique pas au-delà de 3 bandes et ne saurait se substituer à une analyse fine des données d'entrée pour toute conclusion astrophysique.

Dans les résultats d'Orion de la fig. 4.11, l'image (a) correspond à la carte de segmentation et l'image (b) à la composition colorée dans l'espace de couleurs TSL. L'image (c) a été obtenue en effectuant une simple ACP par classe et en projetant les 3 premières images résultantes de l'ACP sur les plans R, V et B.

Cette image montre que l'ACP à elle seule n'est pas une méthode appropriée pour la visualisation des images astronomiques. En effet, dans la composition obtenue, aucune variation intra-classe n'est mise en évidence et l'image résultante correspond globalement à la colorisation de la carte de segmentation. L'image (d) est la composition colorée RVB obtenue avec la méthode de P. Scheunders (ACP locale sur de petites imageries 2×2). L'image résultante met en évidence la zone centrale mais ne permet aucune interprétation de celle-ci (couleur homogène). La partie rouge autour de la zone centrale (correspondant au nuage de gaz) n'apporte aucune information supplémentaire par rapport à une composition colorée RVB triviale (fig. 4.10). L'utilisation de petites imageries ainsi que d'une simple ACP ne permet donc pas de dégager les comportements intéressants présents dans les observations. Dans la figure 4.12, la carte de segmentation (a) comporte dix classes. L'influence du nombre de classes a un effet direct sur la répartition des couleurs dans la composition TSL. Ici, les dix classes doivent être réparties sur l'axe L et chacune d'entre elles n'a donc que très peu de degrés de liberté dans le cône TSL. Ainsi une carte de segmentation avec peu de classes permet à chaque classe d'occuper un grand volume dans l'espace TSL et ainsi de traduire les variations de luminance observées dans les images originales. Pour Orion, le champ des étiquettes avec un nombre de classes élevé contraint trop l'expression des variations intra-classes et limite alors la qualité de la représentation.

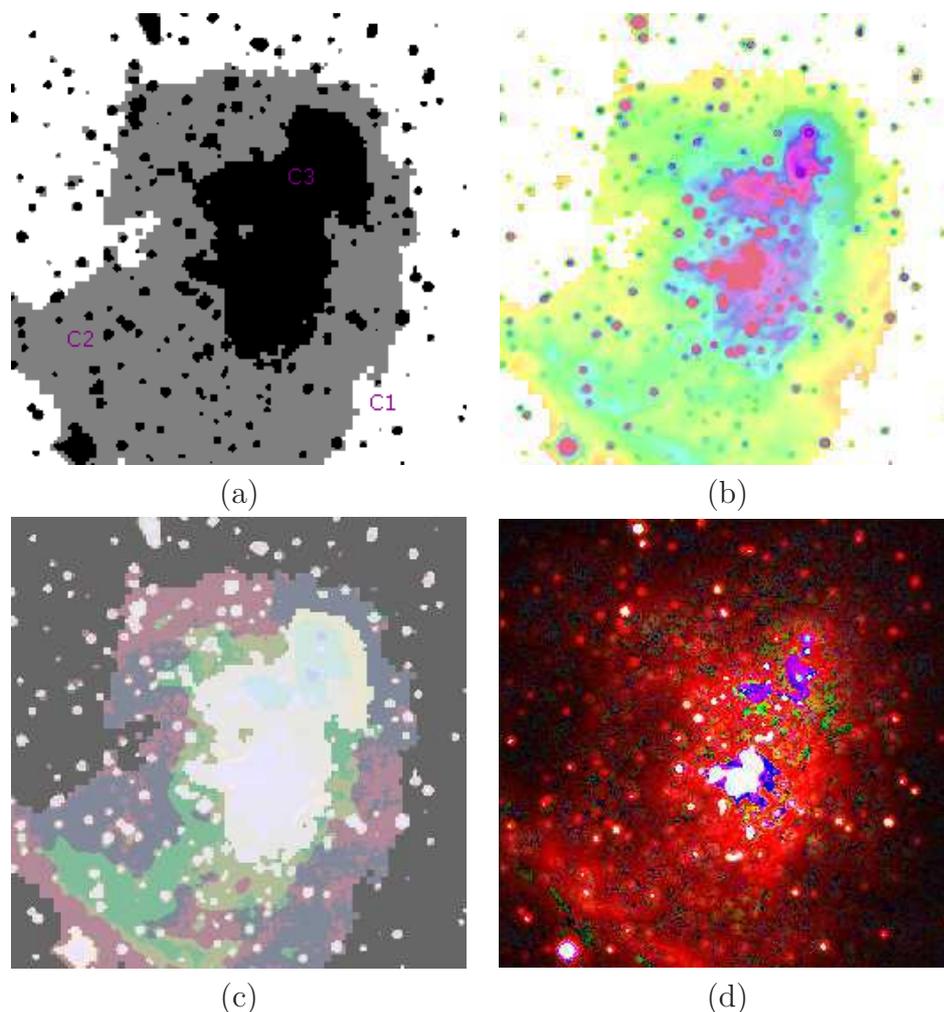


FIG. 4.11 – ORION : (a) : Carte de segmentation en 3 classes. (b) : Composition colorée TSL. (c) Composition colorée RVB par simple ACP par classe. (d) Composition colorée RVB par la méthode de P. Scheunders. Les 3 classes différencient le fond (c_1), l'enveloppe diffuse (c_2) et la zone centrale (c_3) ainsi que les étoiles les plus brillantes du champ. La composition (b) fournit ici en jaune-vert la classe c_2 et en bleu-magenta la classe c_3 . La zone BN/KL repérée en haut à droite dans la bande K ainsi que celle des étoiles brillantes du Trapèze dans la bande H sont bien traduites sur la composition colorée. La composition (c) par ACP sur les classes est totalement dominée par la carte de segmentation et exprime mal la variance des pixels à l'intérieur de leur classe. L'image (d) produite par ACP locale exagère les contrastes locaux, par exemple dans la zone centrale en isolant la zone centrale (en blanc) de son environnement immédiat (en bleu foncé) induisant une idée de différenciation spectrale injustifiée. On peut cependant remarquer que la composition (b) ne met pas correctement en valeur la zone BN/KL différenciée dans la composition colorée RVB figure 4.10.

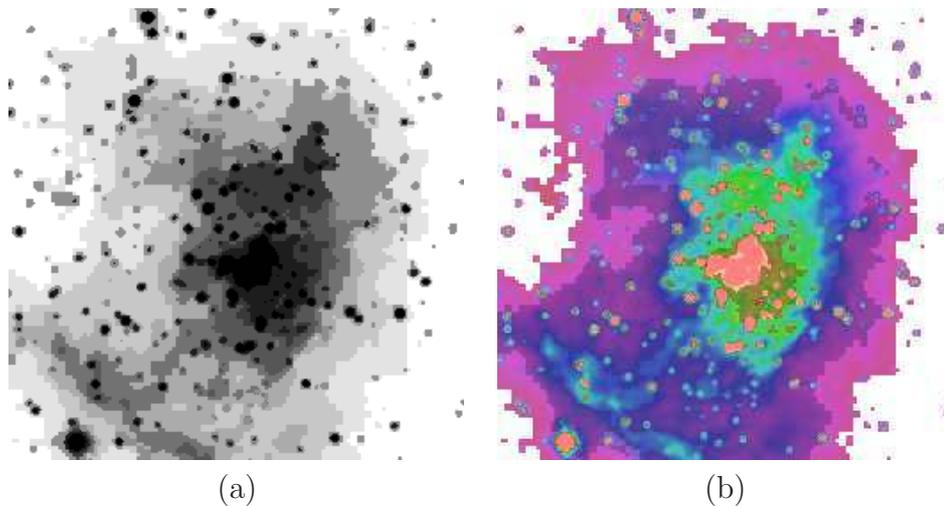


FIG. 4.12 – ORION : (a) : Carte de segmentation 10 classes. (b) : Composition colorée TSL. La répartition des couleurs est contrainte par le découpage en classes. Ici, 10 classes doivent être propagées sur l'axe des luminances, ce qui complique la différenciation visuelle sur la luminance et limite d'autant plus la palette de teintes et saturations disponibles dans le cercle T,S attribué à chaque classe. Un petit nombre de classes est préférable (fig. 4.11) et permet en général d'identifier les principales catégories de comportements spectraux en présence, 2 à 4 typiquement. Si une de ces classes réunit des pixels de comportements spectraux très différents, *i.e.* contient des sous-classes, celles-ci apparaîtront dans la répartition des couleurs sur le cercle T,S (fig. 4.11.b).

4.5.5.2 Résultats sur HDF-474 : 6 bandes de l'ultraviolet à l'infrarouge

Ce jeu d'images sur 6 bandes (fig. 4.13) représente une galaxie du champ Hubble Deep Field.

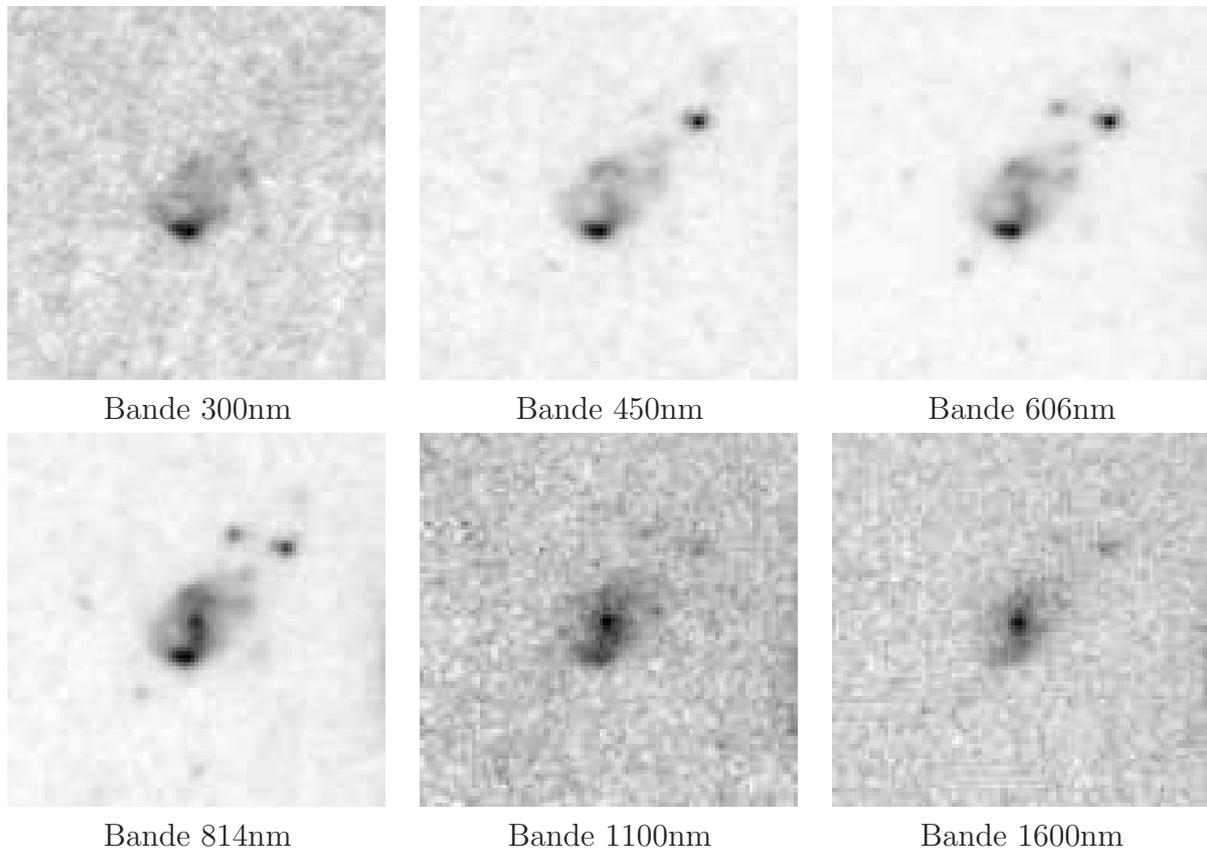


FIG. 4.13 – Visualisation d'une galaxie dans la collection d'images du Hubble Deep Field HDF-474 - 6 bandes. Taille : 101×101 pixels

La structure spirale apparaît clairement sur les 3 dernières bandes, ainsi que le bulbe. Les 3 premières bandes permettent d'identifier les zones de formation stellaire au centre et à la périphérie de la galaxie. La résolution est très bonne et les images peu bruitées. On peut espérer une analyse fine des structures et ainsi les comparer selon leur réponse spectrale. La composition TSL est présentée figure 4.14.b et elle est associée à la carte de segmentation (fig. 4.14.a).

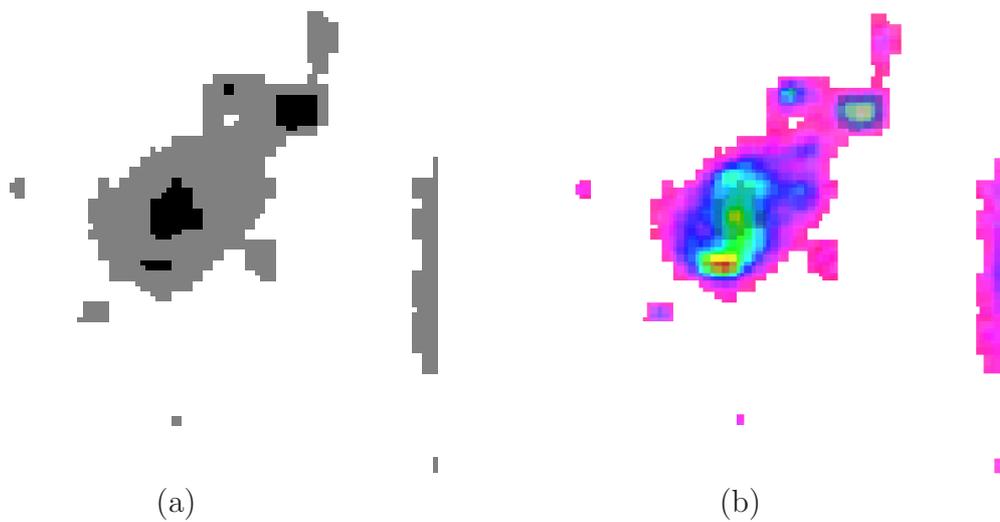


FIG. 4.14 – HDF-474 : (a) : Carte de segmentation 3 classes. (b) : Composition colorée TSL. La carte de segmentation fait apparaître une différence de saturation dans la classe la plus brillante entre la zone d'étoiles brillantes en haut à droite visible sur les dernières bandes et la zone affichée en rouge-jaune issue de la même classe. La variation des pixels se traduit en écart de couleur et de saturation. La composition colorée synthétise correctement l'information présente dans les six bandes originales (zones d'étoiles brillantes et structure en spirale). Elle permet de mettre en évidence les zones d'intérêt pour une étude plus approfondie : zone verte en spirale, et voisinage immédiat.

La figure 4.15 présente un deuxième résultat sur la galaxie HDF474. Cependant la carte de segmentation comporte désormais 6 classes (figure 4.15.a). La composition colorée résultante est présentée (figure 4.15.b).

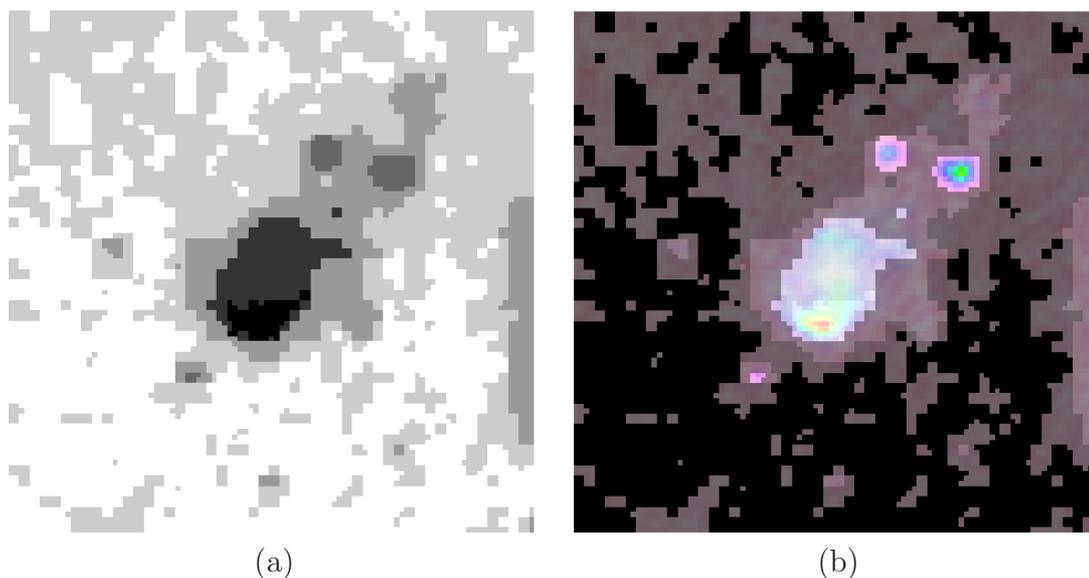


FIG. 4.15 – HDF-474 : (a) : Carte de segmentation 6 classes. (b) : Composition colorée TSL. Dans la carte de segmentation obtenue, on peut remarquer que le fond a été sur-segmenté. Cette partie du fond sur-segmentée se retrouve donc dans la composition colorée. On peut remarquer, par rapport à la figure 4.14.b que la zone centrale de la galaxie est beaucoup moins colorée. En effet, étant donné que le nombre de classes est plus élevé dans ce résultat, chaque classe possède donc une zone plus restreinte dans l'espace TSL. Comme pour la figure 4.12.b, un nombre de classes élevé diminue la plage de valeurs pouvant être prise par les pixels de chaque classe étant donné que 6 classes doivent être réparties sur l'axe de la luminance au lieu de 3 dans la figure 4.14.

4.5.5.3 Cube de données radio : données IRAM du disque GG Tauri

Dans un cube de données radio, telle que la série IRAM constituée de 48 images du disque de GG Tauri (GG correspondant à un code alphabétique caractérisant les étoiles variables), il n'est pas possible de visualiser en un coup d'oeil l'ensemble des données. Pour effectuer une composition colorée de ce cube de données, une réduction a été préalablement effectuée selon la méthode de regroupements. Les 48 bandes sont groupées dans 6 clusters de 8 images chacun en utilisant des mesures de similarités inter-images à partir de la distribution multi-échelle des valeurs des pixels. Une ACP est ensuite effectuée sur chaque cluster et seule l'image correspondante à la plus grande valeur propre est conservée au titre de représentant du cluster (fig. 4.16).

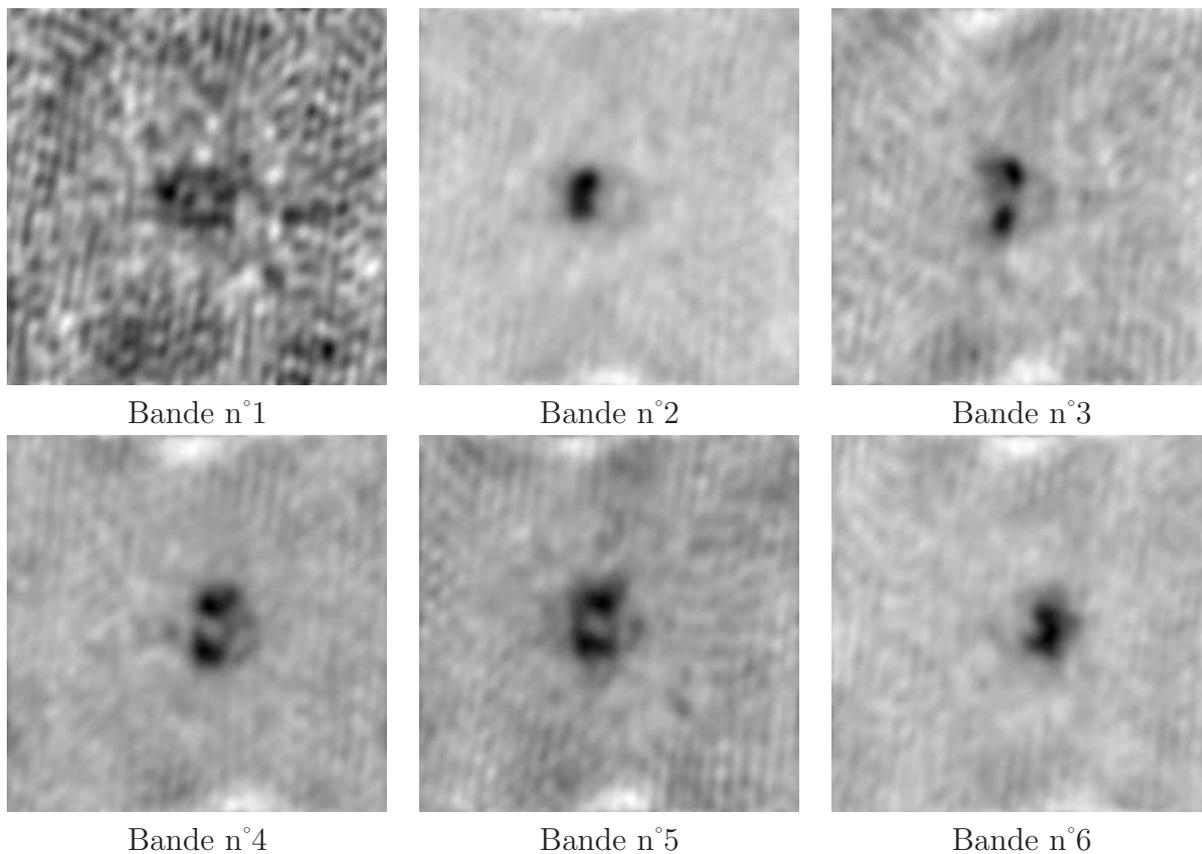


FIG. 4.16 – Données radio IRAM de la zone de GG Tauri. Réduction des 48 bandes originales en 6 composantes principales par l'analyse en composantes principales. Taille : 256×256 pixels.

Ce procédé de réduction fonctionne bien notamment en raison de la forte corrélation inter-bandes. L'objet visualisé ici est un nuage de gaz en rotation autour d'une étoile ; on cherche à analyser le champ de vitesse de cet ensemble. La carte de segmentation construite sur les 6 bandes réduites est reproduite figure 4.17.a et la composition colorée TSL est présentée dans la figure 4.17.b.

L'analyse de ce cube par décomposition du spectre en composantes gaussiennes permet d'aller plus loin. Les images synthétiques obtenues (fig. 4.18) présentent la répartition

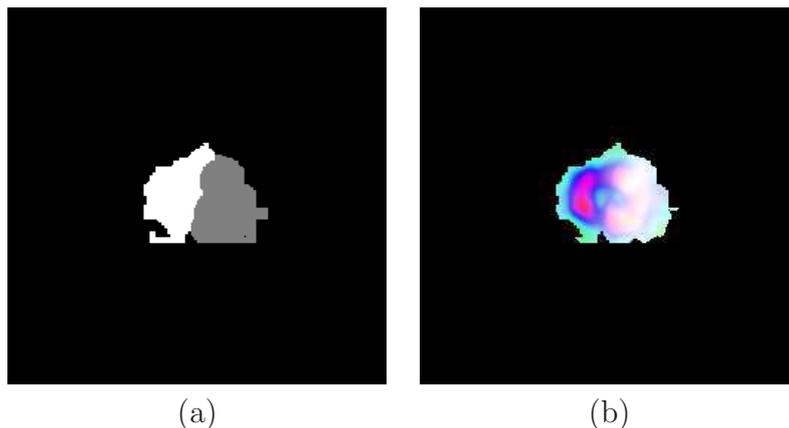


FIG. 4.17 – Données IRAM : (a) : Carte de segmentation 3 classes. (b) : Composition colorée. La composition colorée fait ressortir une opposition gauche-droite des 2 demi-anneaux saturés. Cette opposition est caractéristique du champ de vitesse que l'on cherche à étudier (fig. 4.18.b). La méthode de projection par AFD met bien en valeur la variance des coefficients des composantes principales pour les pixels sélectionnés appartenant à l'objet.

moyenne des intensités, *i.e.* la réponse spectrale moyenne par pixel, similaire à l'image des moments d'ordre 0 (fig. 4.18.a) ainsi que le champ de vitesse que l'on cherche à étudier (fig. 4.18.b).

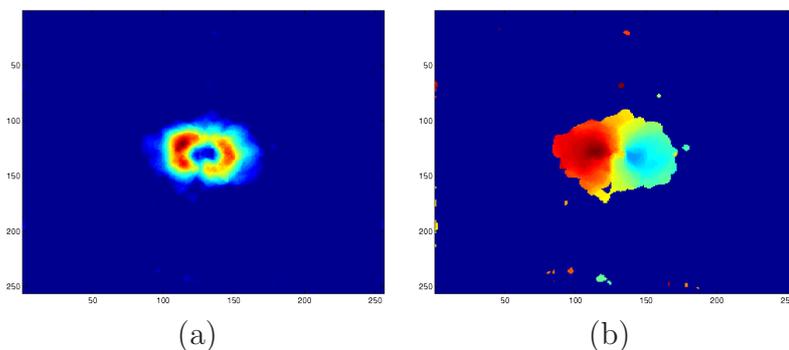


FIG. 4.18 – Données IRAM : (a) : Image Moyenne des pixels "objet" calculée sur les 48 bandes originales (après seuillage du fond). (b) : Champ de vitesse extrait de l'analyse spectrale du cube.

On peut remarquer sur ces images la forme caractéristique des demi-anneaux représentatifs du champ de vitesse d'un disque incliné en rotation.

La méthode de visualisation proposée ici permet de synthétiser une observation multispectrale sous la forme d'une composition colorée dans l'espace TSL. Cette image couleur met en valeur les différentes zones de l'observation au travers d'une variation de teinte, de saturation et de luminance. Cependant, l'information de couleur astronomique est perdue dans cette représentation. En effet, les couleurs des compositions colorées sont arbitraires et n'ont pas de signification physique particulière. Une deuxième méthode de visualisation établie avec les astronomes est proposée dans la partie suivante. La paramétrisation des canaux T, S et L diffère de la méthode précédente et permet une meilleure prise en compte des phénomènes astrophysiques liés aux objets.

4.6 Deuxième méthode de visualisation

La méthode de visualisation précédemment introduite comporte quelques inconvénients. D'une part, les couleurs et les saturations de la composition colorée sont guidées par la variance principalement. Ces compositions colorées peuvent être difficilement interprétable du point de vue de la similarité : comment interpréter les écarts entre luminosité, saturation et teinte entre deux pixels particuliers ? De deux zones de la composition colorée de même couleur et de même saturation, on peut seulement déduire qu'elles présentent le même comportement spectral mais en aucun cas déduire des caractéristiques sur la forme du spectre des pixels.

D'autre part, l'utilisation d'une analyse factorielle discriminante qui projette les spectres dans un espace peu intuitif peut rendre l'interprétation de la composition résultante délicate de même que la comparaison des zones dégagées dans l'image.

La méthode présentée ici est davantage liée au processus d'interprétation mis en oeuvre par la communauté astronomique lors de la visualisation d'images multispectrales. Dans la pratique, les astronomes interprètent les contributions spectrales des images par une table de couleurs implicite qui suit le spectre de la lumière visible : bleu-violet pour les petites longueurs d'ondes et rouge pour les grandes. Ce code d'interprétation est utile pour notre cas. Une composition colorée d'une observation astronomique doit donc mettre en valeur le comportement spectral dominant de chaque pixel. La couleur de chacun d'eux doit être directement liée à la forme de leur spectre associé. Ainsi le spectre en un site s de l'observation Y présentant une raie d'émission dans les grandes longueurs d'ondes (resp. petites longueurs d'ondes) doit apparaître en rouge (resp. bleu) dans la composition colorée. Si on observe des images dont les différentes bandes s'étalent en dehors du spectre visible, on peut conserver la palette appliquée dans le domaine visible (*i.e.*, bleu pour les faibles longueurs d'ondes et rouge pour les fortes). L'image colorée doit également donner une information de variabilité spectrale, par exemple en faisant apparaître une différence visuelle entre un spectre de raies et un continuum. Dans la première section nous décrivons la nouvelle stratégie d'affectation des canaux TSL en vue d'obtenir une composition colorée plus pertinente. Puis, dans une deuxième section, celle-ci est validée sur quelques images astronomiques et comparée aux résultats obtenus avec la première méthode.

4.6.1 Modèle TSL

L'imagerie multispectrale permet d'avoir accès à une image composée d'un ensemble de spectres. Cette information spectrale est très utile à l'astronome dans le sens où elle renseigne sur la physique, chimie, thermodynamique de l'objet étudié. En particulier, la connaissance des raies d'émission et d'absorption ainsi que leur longueur d'onde associée (ultra-violet, visible, infra-rouge...) est essentielle dans le processus d'interprétation d'une observation. Par exemple, dans le cas d'une image tribande, une projection de chaque bande sur les trois couleurs RVB permet de visualiser pour les objets en présence, les réponses dans chaque bande. Néanmoins, lorsque le nombre de bandes augmente, une représentation colorée plus précise est nécessaire pour prendre en compte l'information portée par le spectre de chaque pixel.

Dans la méthode proposée, la couleur de chaque pixel dans la composition couleur dépend du spectre qui lui est associé. Pour chaque spectre Y_s de l'observation, on détermine un indice de couleur codé sous la forme d'un triplet :

$$\tau_s = \{B(\text{bleu}), V(\text{vert}), R(\text{rouge})\}$$

Cet indice est obtenu en groupant (dans l'ordre des longueurs d'ondes) les bandes en trois intervalles. Chaque spectre de l'image est alors découpé en trois parties distinctes (figure 4.19) (qui correspondent aux trois couleurs : bleu, vert, rouge, ordonnées selon le spectre de la lumière visible). La valeur maximale de l'intensité est obtenue pour chaque partie et stockée dans un triplet τ_s représentant la couleur globale du pixel, dans l'espace RVB. Ainsi pour un spectre ayant une raie d'émission dans les grandes longueurs d'ondes (raie présente dans le troisième cluster (figure 4.19)), la couleur du pixel associée dans la composition colorée sera rouge. La conversion du triplet τ_s en une teinte compatible au

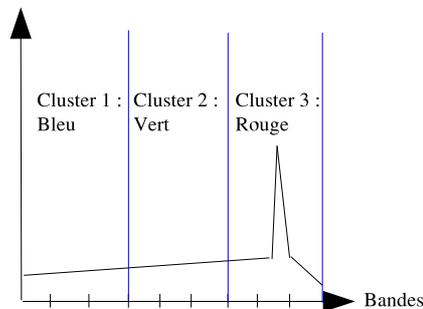


FIG. 4.19 – Groupement des bandes en trois intervalles

format TSL fournit la valeur de la composante T.

Néanmoins, cette méthode de regroupement aboutit, pour certains spectres de profils très différents, à une même teinte. Le but étant de différencier un comportement spectral plat d'un comportement plus variable (par exemple, raies d'émission ou d'absorption), un *indice de variabilité spectrale* (variance statistique) paramétrant le canal de la saturation S permet, d'une part, d'apporter une information spectrale supplémentaire et, d'autre part, de différencier des configurations de spectres différentes aboutissant à une même teinte. Ainsi, en utilisant la variance de chaque spectre Y_s comme indice de variabilité spectrale

pour paramétrer l'axe S, on met en valeur l'aspect lisse ou au contraire irrégulier du spectre. Un spectre très variant (donc composé de raies) apparaîtra dans une couleur pâle (saturation faible), alors qu'un spectre peu variant (continuum par exemple) apparaîtra dans une couleur vive (saturation forte). Ce choix d'ordonnement du canal S (variant : pâle, peu variant : foncé) peut être inversé facilement dans l'algorithme de visualisation selon les besoins de l'interprétation.

Une analyse en composantes principales par classe (à l'aide de la carte de segmentation) est alors effectuée pour paramétrer l'axe L. Chaque spectre est projeté sur la première composante principale issue de l'ACP. La composante L est proportionnelle à la projection du vecteur considéré sur le premier vecteur propre correspondant à sa classe. Ainsi les vecteurs responsables du maximum de variance dans la classe sont affichés avec une luminosité forte. Au contraire, les pixels de comportement proche de la moyenne de leur classe sont affichés avec une luminosité plus faible. Cette stratégie tend à mettre en évidence les différences de comportements entre les pixels d'une même classe.

L'utilisation d'un indice de couleur nécessite l'accès aux spectres de l'observation. Lorsque $c > 10$, cette méthode ne pourra pas être appliquée puisque la méthode de réduction de données utilisée réorganise l'information spectrale sur de nouveaux axes.

La figure 4.20 résume la deuxième méthode de visualisation colorée.

Dans la partie suivante, la méthode est validée sur des images astronomiques multibandes (galaxie HDF (Hubble Deep Field)) ainsi que sur une image issue du domaine de la télédétection. Elle est également comparée aux résultats obtenus avec la première méthode de composition colorée.

4.6.2 Résultats

La figure 4.21 présente une image multibande (6 bandes) de la galaxie HDF-474 (identique à la figure 4.13). La figure 4.22.a correspond à la carte de segmentation obtenue par quadarbre markovien sur ces 6 bandes tandis que la figure 4.22.b est la composition colorée d'HDF474 obtenue avec la première méthode. La figure 4.22.c est la représentation colorée obtenue avec la méthode des indices colorés et la figure 4.22.d est la même composition colorée mais en ayant inversé l'axe de la saturation.

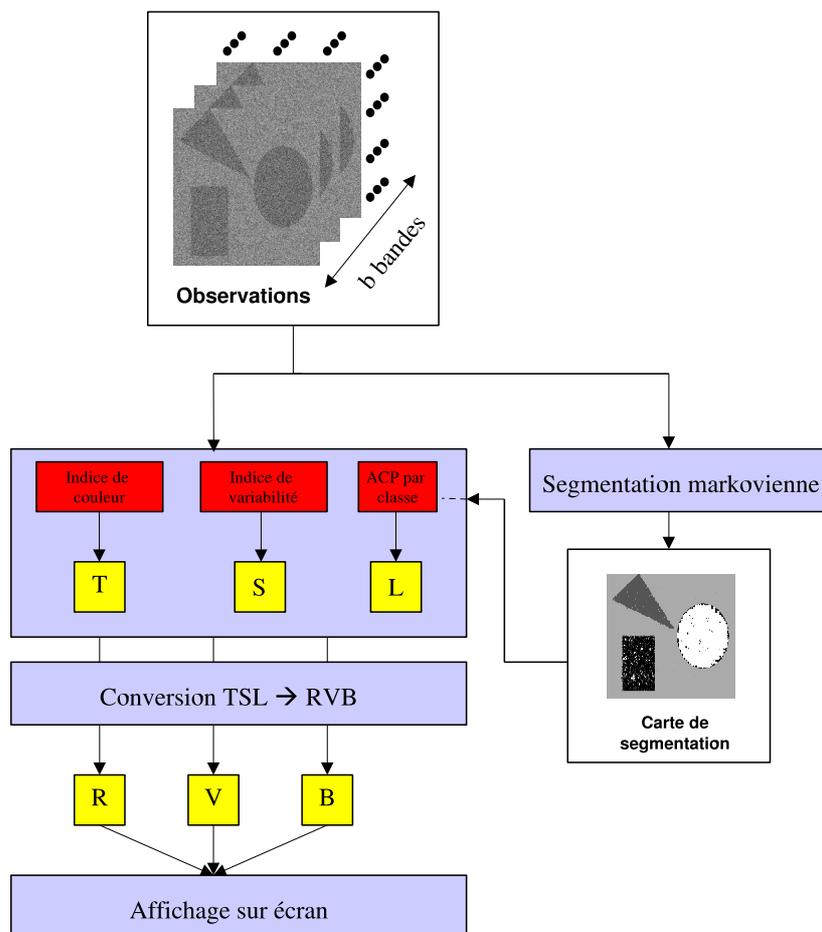


FIG. 4.20 – Deuxième méthode de visualisation de cubes de données multicomposantes par indice de couleur, de variabilité et ACP locale.

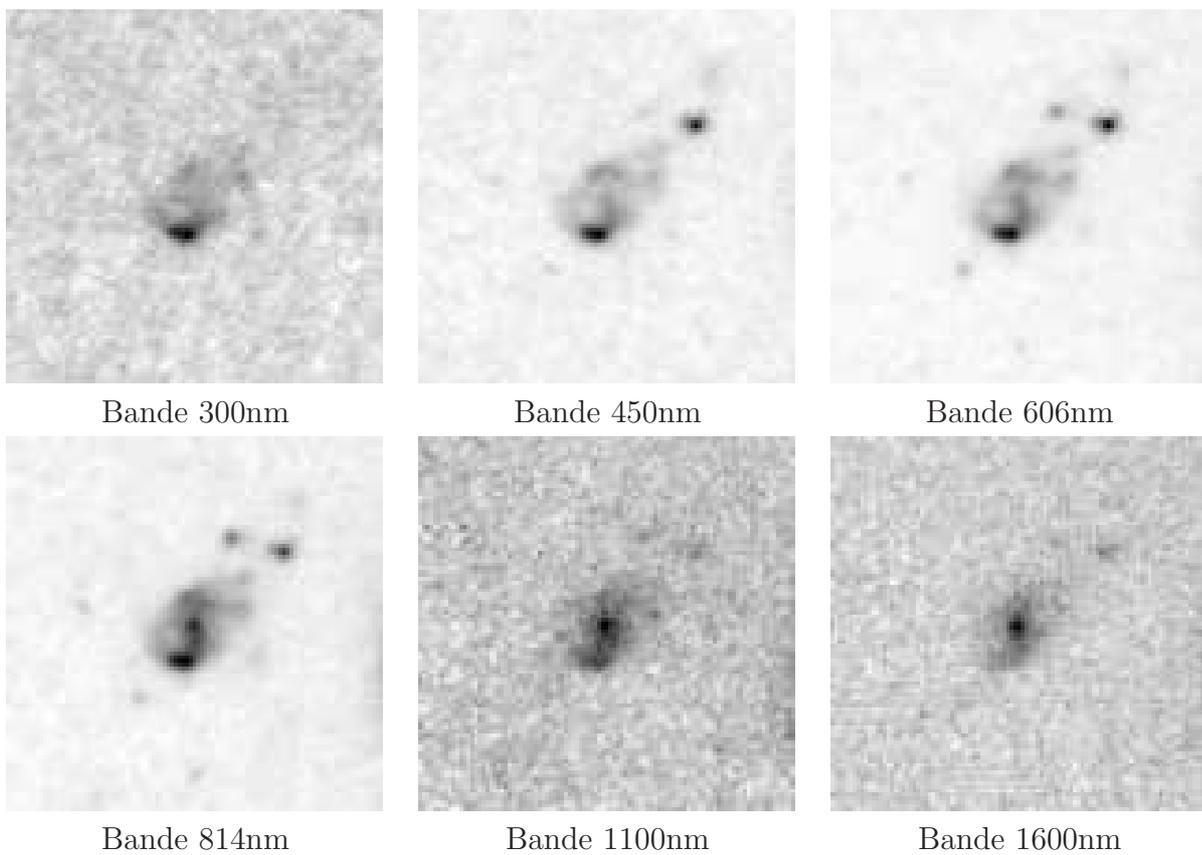


FIG. 4.21 – Galaxie de la collection d'images du Hubble Deep Field HDF-474 - 6 bandes.
Taille 101×101 pixels

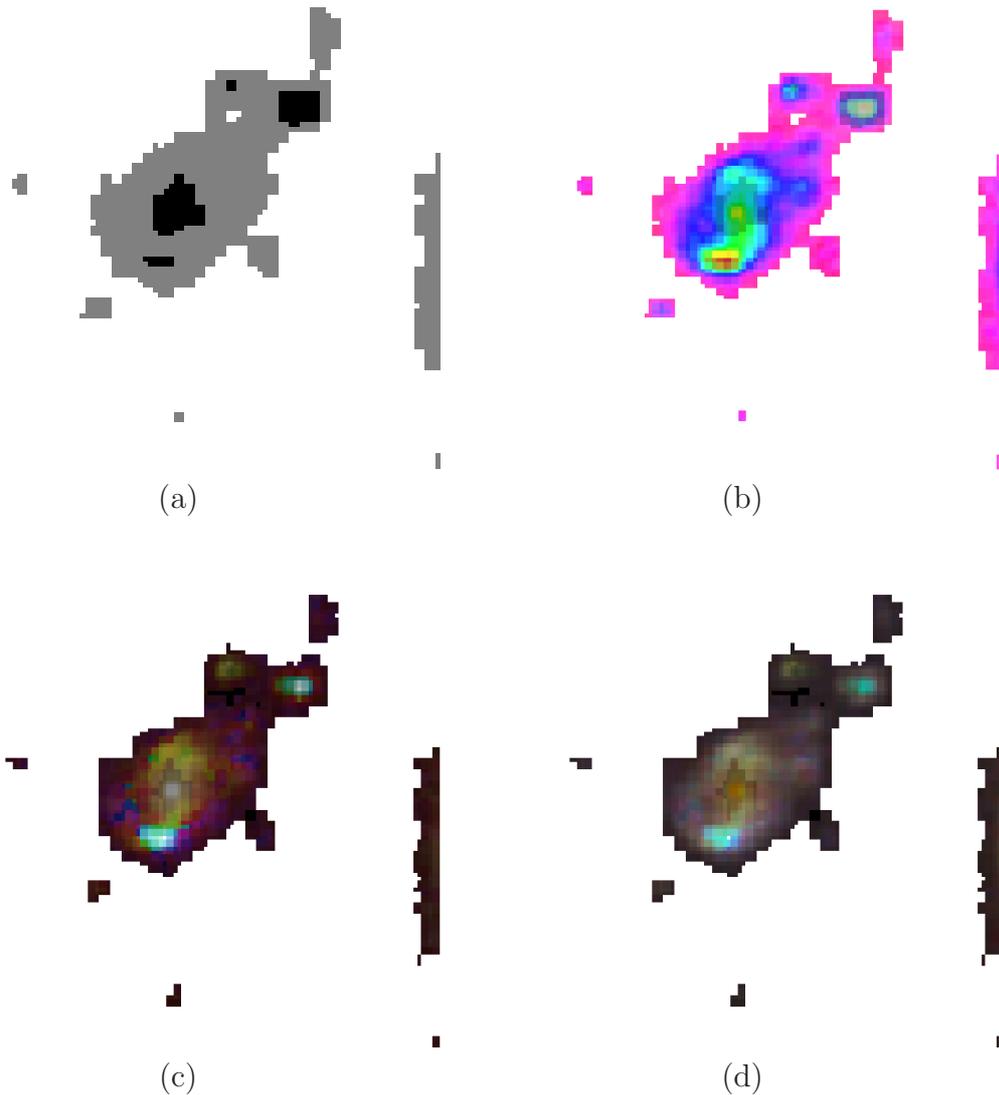


FIG. 4.22 – (a) : carte de segmentation (trois classes). (b) : composition colorée avec la première méthode. (c) : composition colorée avec la méthode des indices colorés. (d) : composition colorée avec la méthode des indices colorés et axe de la saturation inversé. On peut remarquer en comparant les compositions colorées (b) et (c) que la forme en spirale de la galaxie apparaît plus nettement sur la composition (c). On distingue également sur celle-ci, des zones bleues très pâles (au centre et en bas de la galaxie ainsi qu'en haut à droite de l'image) qui correspondent à des zones de formation stellaire, présentes dans une majorité des bandes de l'observation (au moins trois bandes sur les six). Ces zones apparaissent dans une teinte très pâle montrant ainsi la présence d'un spectre de raies (fortement variant). L'image (b) ne permet pas de se livrer à une interprétation spectrale aussi fine de l'observation. En effet, les couleurs, arbitraires, et les saturations dans cette composition dégagent uniquement des zones de comportements spectraux identiques, ces zones se retrouvant par ailleurs dans la composition (c). Les sous-structures globulaires fournies par les images originales sont davantage mises en valeur en (d) où les zones de faible variance spectrale sont en pastel (*i.e.* faible saturation) et les zones de pics de variance en couleur intense (forte saturation).

La figure 4.23 est une autre galaxie de la collection HDF. La figure 4.24 présente les résultats de composition colorée associés à l'observation.

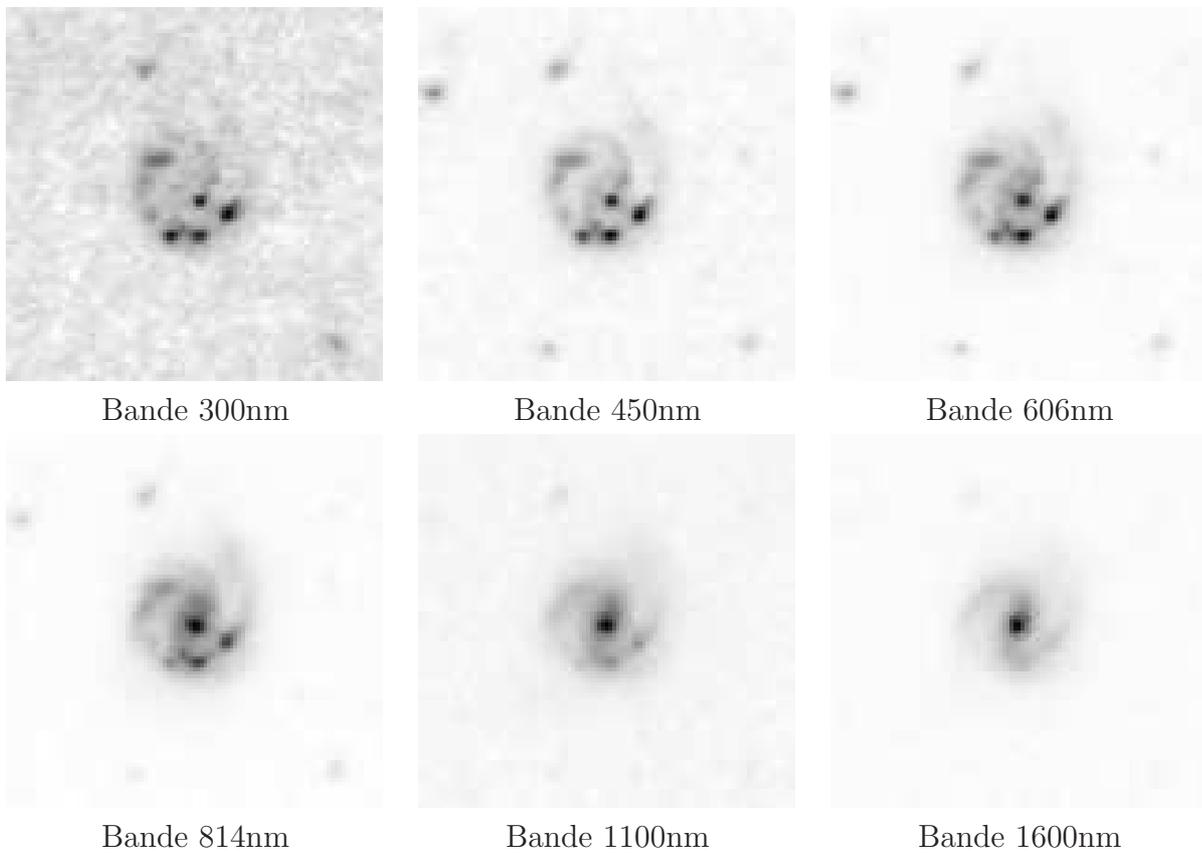


FIG. 4.23 – Galaxie de la collection d'images du Hubble Deep Field HDF-550 - 6 bandes.
Taille 101×101 pixels

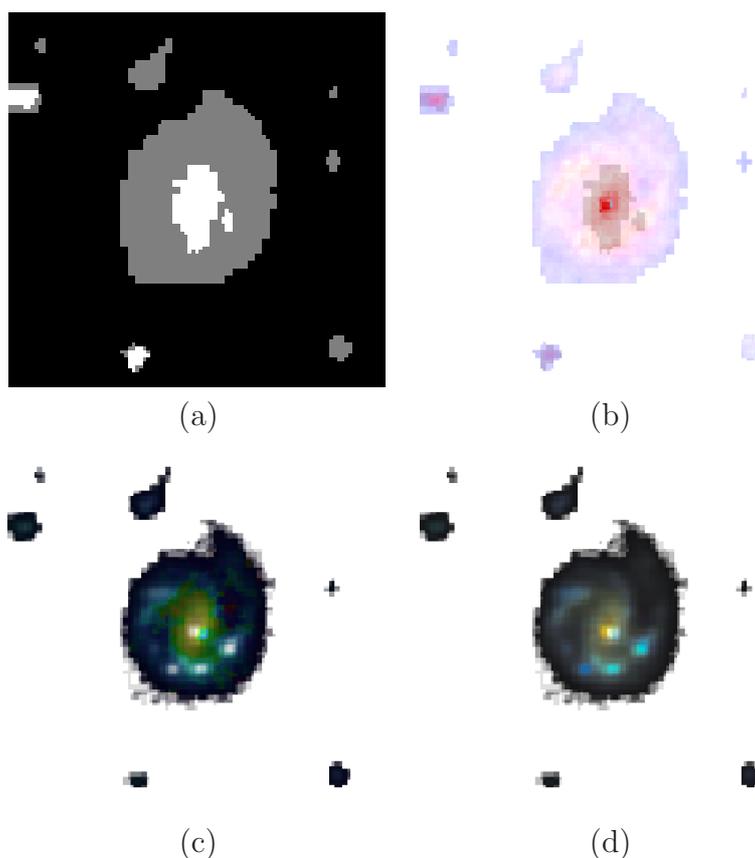


FIG. 4.24 – (a) : carte de segmentation (trois classes). (b) : composition colorée avec la méthode précédente. (c) : composition colorée avec la méthode des indices colorés. (d) : composition colorée avec la méthode des indices colorés et axe de la saturation inversé. On peut remarquer que les figures (c) et (d) révèlent beaucoup mieux la structure spirale de la galaxie HDF550. On peut également constater que les zones de formation stellaires (points blancs le long de la structure spirale) sont présentes dans les composition (c) et (d) tandis qu'elles sont absentes de la figure (b). Cet exemple illustre parfaitement l'apport de l'indice de couleur dans le processus de composition colorée. En effet, ces zones de formations stellaires présentent une réponse spectrale différente du reste de la galaxie. Ainsi l'indice de couleur permet de mieux les discriminer. On peut également remarquer dans la figure (b) l'influence de l'approche par analyse factorielle discriminante. Une couleur globale a été affectée à chaque classe, limitant ainsi la plage de couleurs que peut prendre chaque pixel dans la classe : les pixels d'une même classe sont donc trop contraints dans un sous-espace de l'espace TSL. Cependant, en (b) on remarque que la forme spirale de la galaxie apparaît en blanc (saturation faible), à la périphérie de la zone centrale. La spirale a donc été mise en valeur grâce au deuxième axe de l'analyse factorielle discriminante. Dans l'image (b), la carte de segmentation utilisée limite la plage de couleurs d'une classe à cause de l'analyse factorielle discriminante qui affecte une couleur globale pour chaque classe. Par contre en (c) et (d), l'utilisation de l'indice de couleur appliqué en chaque pixel permet de dégager les composantes intra-classes n'apparaissant pas ou peu dans (b).

La figure 4.25 rappelle les données originales de télédétection et la comparaison des deux méthodes est présentée figure 4.26.

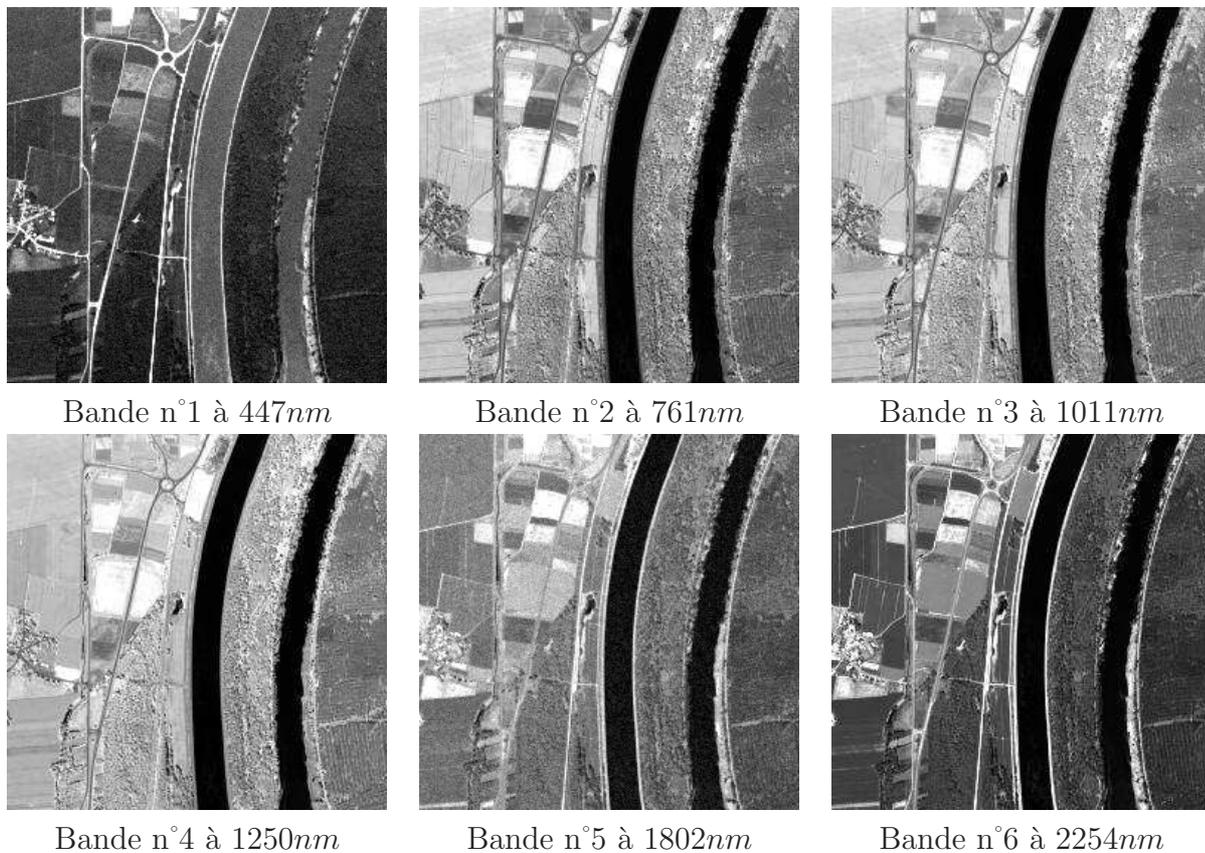


FIG. 4.25 – Télédétection aérienne : 6 bandes extraites d'un cube de données prises au dessus de la forêt de Hartheim à l'aide du capteur hyperspectral HyMap (128 canaux), à une résolution de 4m au sol . On y observe le Rhin, une zone de forêt à droite, le réseau routier avec un rond point en haut, des champs et une zone d'habitation (village). Taille : 378×378 pixels. Nous remercions J. Label-Nachbrand (LSIIT, Equipe TRIO, UMR CNRS 7005, STRASBOURG) pour la mise à disposition de ces images.

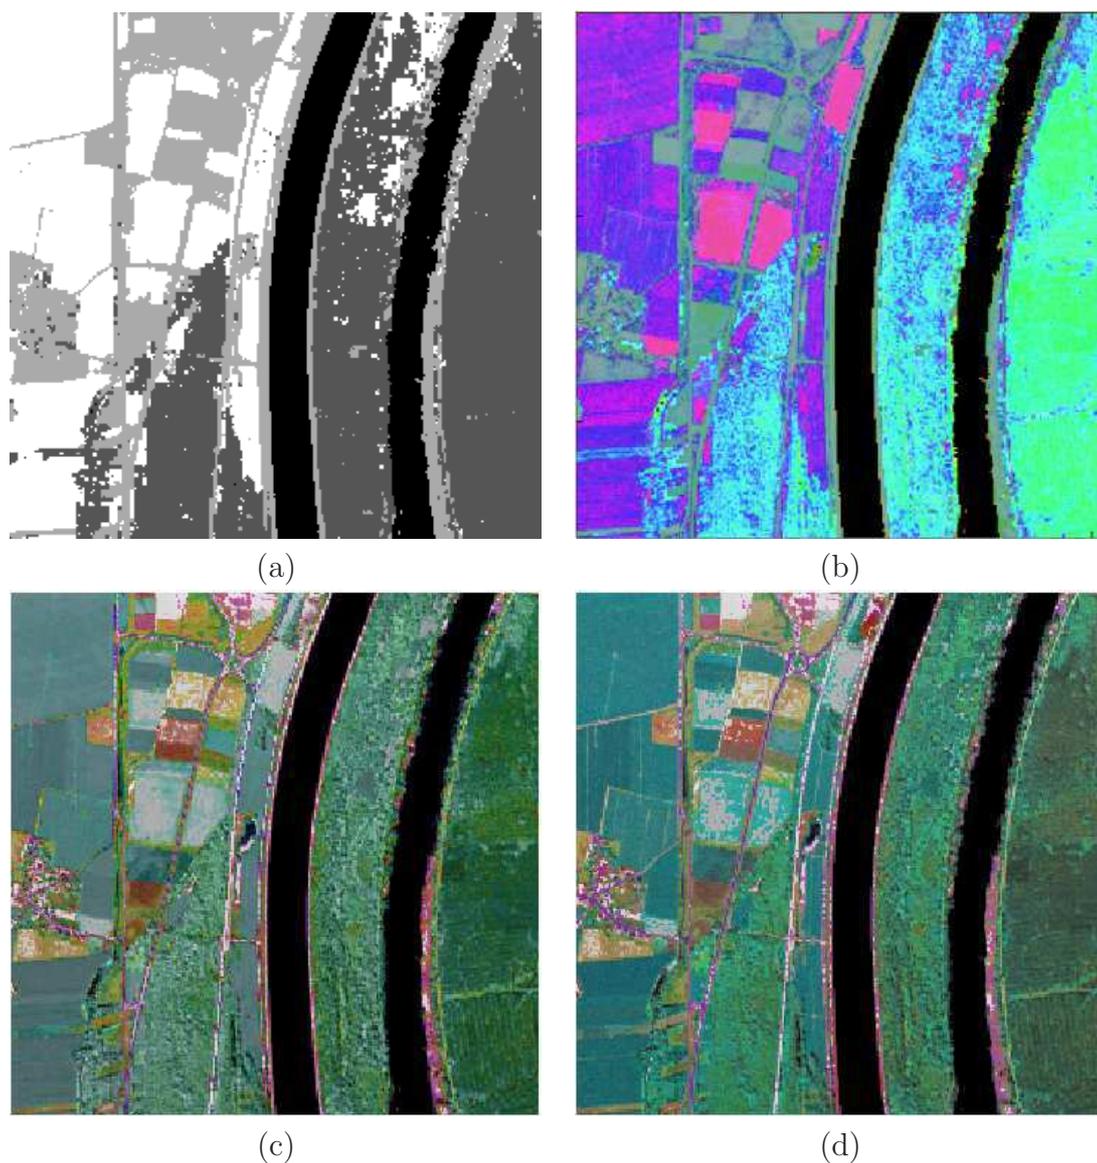


FIG. 4.26 – (a) : Carte de segmentation en 4 classes de la forêt de Hartheim. (b) : Composition colorée TSL obtenue avec la première méthode. (c) : composition colorée obtenue avec la deuxième méthode. (d) : composition colorée obtenue avec la deuxième méthode et axe de saturation inversée. Comme pour la figure 4.24, en (b) on peut constater que chaque classe possède une couleur globale et que les variations spectrales dans l’observation sont traduites dans (b) par une variation fine de la teinte et de la saturation. En (c) et (d), l’indice de couleur révèle les détails liés à la forme des spectres de l’observation tandis que l’indice de variabilité met en valeur la forme piquée ou au contraire lisse des spectres au travers d’une variation de la saturation. Les images (c) et (d) sont assez similaires malgré l’inversion de l’axe de la saturation. Les valeurs sur cet axe sont donc toutes proches de 0.5. Cependant la composition (d) fait apparaître un réseau de chemin séparant les champs entre eux (notamment en haut à gauche de l’image (d)).

4.7 Conclusion

Les images astronomiques multispectrales contiennent une information riche et complexe selon l'axe des longueurs d'ondes, énergies. Une représentation colorée pertinente doit permettre l'interprétation des observations en se basant sur la différenciation des profils spectraux présents dans l'image mais aussi sur la présence ou non de continuum et/ou de raies d'émission (l'interprétation et la distinction de telles raies étant essentielles). La première méthode de composition colorée, dans l'espace TSL, permet de différencier les grands comportements spectraux des observations en projetant les spectres dans un espace maximisant la variance inter-classes et minimisant la variance intra-classes grâce à l'information sur les classes apportée par la carte de segmentation obtenue sur le quadarbre markovien. Chaque classe se verra ainsi assignée une teinte et une saturation globale et les fines variations intra-classes se traduiront par une variation fine de ces deux mêmes axes. L'interprétation de cette composition colorée reste d'ordre global.

Ainsi, à partir d'une telle représentation, on peut dégager des zones de comportements spectraux identiques (apparaissant dans des teintes et saturations identiques) sans toutefois permettre l'analyse fine des couleurs et saturation de chacun des spectres de l'image.

La deuxième méthode de visualisation présentée se base d'une part, sur un indice coloré τ_s afin de mettre en avant la "couleur" (au sens astronomique du terme) de chaque pixel et d'autre part, sur un indice de variabilité spectrale reflétant le caractère variant (par exemple, présence de raies d'émission) ou peu variant (par exemple, continuum) des spectres de l'observation. Enfin, une analyse en composantes principales met en évidence, par une variation de luminosité, les différences entre les spectres appartenant à une même classe. Cette approche est beaucoup plus pertinente dans le cadre d'une analyse astronomique. En effet, chaque canal est paramétré par une valeur représentative et facilement interprétable du comportement spectral de chaque pixel. Cette nouvelle méthode a été validée et comparée à la première méthode de visualisation montrant ainsi l'utilité d'une approche spectrale plus locale, facilitant le travail d'interprétation et mettant en valeur un plus grand nombre de caractéristiques spectrales (et donc astronomiques). L'astronome se retrouve alors dans un système d'interprétation familier du moins pour les données obtenues dans le spectre visible. Cette deuxième méthode de visualisation a été implémentée par J.J. Claudon dans la plateforme Aïda et sera prochainement disponible directement dans le logiciel Aladin.

La méthode par indice colorée n'est cependant pas applicable sur des données réduites (comme c'est le cas pour la première méthode). En effet, la réduction par *ACP* ou *ACI* va recombinaison la progression de l'information spectrale (typiquement les raies et leur position) et la couleur dans la représentation colorée ne pourra donc pas être mise en relation avec l'observation. Une solution possible à ce problème serait de travailler directement sur le cube hyperspectral entier et déterminer une paramétrisation différente de l'axe T (en effet l'indice de couleur serait imprécis sur des images dont le nombre de bandes est supérieur à 10). Cette nouvelle approche nécessiterait l'obtention d'une carte de segmentation du cube de données hyperspectral. Cependant, les algorithmes de classification usuels se heurtent au délicat problème du phénomène de Hughes. Il convient donc de proposer un outil de segmentation hyperspectrale s'affranchissant de ce phénomène et utilisant la richesse de l'information spectrale dans le processus de classification. Le chapitre suivant

introduit une nouvelle méthode de segmentation de cubes hyperspectraux ($c > 50$) basée sur des critères spectraux et spatiaux. Cette méthode est appliquée et validée sur des images de simulation de champs de galaxies ainsi que sur une image de télédétection.

5 Réduction-segmentation d'images astronomiques hyperspectrales

Introduction

L'imagerie hyperspectrale devient de plus en plus accessible grâce au progrès technologique des capteurs ainsi qu'au nombre croissant de relevés astronomiques. Cependant, les images hyperspectrales obtenues souffrent généralement d'une perte de résolution spatiale au profit d'une augmentation de la résolution spectrale. Chaque spectre de l'image est intégré sur une surface d'autant plus importante que la résolution spectrale souhaitée est forte. En plus de ces relevés hyperspectraux, des programmes de simulations d'objets astronomiques voient le jour. C'est notamment le cas de GALICS¹ (Galaxies In Cosmological Simulations)[65][57] qui est un logiciel de simulation d'évolution de halos de matière sombre et de matières baryoniques basé sur un modèle cosmologique, formant ainsi des galaxies. Cet outil permet d'obtenir de grands cubes de données dont les tailles peuvent atteindre 1000^3 pixels tandis que les relevés astronomiques actuels donnent accès à des images de taille $80 \times 80 \times 400$ pixels au maximum. D'une part, le caractère hyperspectral de ces cubes est très intéressant pour l'analyse astronomique, en effet, de nombreuses propriétés spectrales deviennent alors accessibles et leurs mesures plus précises puisque l'échantillonnage du spectre devient fin. D'autre part, l'étude et l'interprétation de ces cubes de données restent très délicates à cause de la grande dimensionnalité du cube de données. L'obtention d'une carte de segmentation de ces images est donc souhaitable afin de synthétiser l'information du cube hyperspectral sous une forme simple à manipuler, et de faciliter le processus d'interprétation, notamment en mettant en valeur des zones de l'image ayant des comportements spectraux particuliers vers lesquelles l'astronome va pouvoir focaliser son attention. Il pourra, par exemple, étudier les variations du champ de vitesse de l'objet en étudiant les différences entre les positions des raies d'émission/absorption pour chaque spectre appartenant à la même classe. Cependant, l'utilisation de techniques de segmentation standards (méthodes de coalescences, approches statistiques, méthodes markoviennes) montrent rapidement leurs limites dans le traitement de cubes hyperspectraux. En effet, la taille, parfois grand, du cube de données soulève le problème de la "malédiction de la dimensionnalité" [34] : le nombre de bandes augmentant, la quantité de spectres dans l'image reste constante conduisant ainsi à un espace de dimension élevée par rapport aux nombres d'échantillons à disposition. Il est donc nécessaire d'introduire de nouvelles méthodes permettant la segmentation automatique de tels cubes de données. De plus, le caractère hyperspectral des données peut induire

¹<http://galics.iap.fr>

l'utilisation d'une approche spectrale couplée à une approche spatiale afin de segmenter le cube. En effet, la richesse de l'information spectrale ne peut être omise dans le processus de segmentation. Contrairement à la segmentation d'une image monobande/multibande où l'affectation d'une classe à un groupe de pixels se fait en fonction de la distribution de la luminosité vectorielle intra-classe, l'approche spectrale va permettre d'assigner une classe différente à chaque comportement spectral différent dans l'image. L'astronome pourra ainsi directement visualiser le spectre moyen de chaque classe afin de diriger son étude vers la zone dont le comportement spectral répond à ses attentes. Nous présentons dans ce chapitre, une méthode de réduction-segmentation d'images hyperspectrales de champs de galaxies basée sur une technique de projection et sur la méthode des Mean-Shift[19]. Cette méthode offre une segmentation spectrale dans un premier temps, qui alimente un classifieur markovien prenant ainsi en compte la distribution spatiale des données. Enfin, cette méthode met en valeur les principaux comportements spectraux présents dans l'observation au travers d'une base de spectres caractéristiques. La spectroscopie, en astronomie, est un domaine complexe régit par des lois physiques spécifiques. L'étude d'un cube hyperspectral ne peut se faire qu'en connaissant précisément les mécanismes de formation et les problématiques mis en jeu au travers de ces spectres. La première partie de ce chapitre présente donc une introduction avancée à la spectroscopie ainsi qu'à la physique des galaxies. Puis, dans une deuxième partie nous présentons notre méthode de projection couplée à la méthode des Mean-Shift ainsi qu'à une segmentation markovienne par quadarbre ou par algorithme des K-Moyennes (si le nombre de bandes réduites à segmenter dépasse la dizaine). Une troisième partie présente les résultats obtenus sur des images hyperspectrales issues de GALICS, sur un cube de données astronomiques réelles hyperspectrales puis sur une image hyperspectrale simulée fournie par Ch. Pichon (Institut d'Astrophysique de Paris). Enfin, nous présentons et validons l'utilisation de la méthode sur une image issue du domaine de la télédétection, montrant ainsi le caractère générique de l'approche.

5.1 Notations

Notation	Signification
z	Décalage spectral ou redshift
λ	Longueur d'onde
λ_0	Longueur d'onde dans le référentiel du laboratoire
\mathcal{K}	K-correction
\mathcal{E}	Correction d'évolution
R	Rayon dans la galaxie
Y	Observation hyperspectrale
s	Site de l'observation
Y_s	Spectre de Y au site s
B	Base de projection
β_i	Spectre i de la base de projection B
n	Nombre de spectres dans la base de projection B
P	Distribution des poids de projection dans \mathbb{R}^n
ω_{si}	Poids de projection i associé au spectre Y_s
\hat{Y}_s	Reconstruction de Y_s
ζ	Erreur quadratique de reconstruction globale
ζ_s	Erreur quadratique de reconstruction au site s
C	Matrice de covariance
X	Distribution de points
$\#$	Cardinal
x_i	Echantillon de la distribution de points
$f(x)$	Densité de probabilité
$\hat{f}(x)$	Densité de probabilité estimée
$\nabla f(x)$	Gradient de $f(x)$
K	Fonction noyau
$K_E(x)$	Noyau d'Epanechnikov
h	Taille de la fenêtre de lissage dans l'algorithme des Mean-Shift
d	Dimension des données
C_d	Volume de l'hypersphère unité de dimension d
$S_h(x)$	Hypersphère de rayon h centrée en x
n_x	Nombre de points contenus dans $S_h(x)$
\mathcal{N}	Loi normale
π_i	Pondération de la gaussienne i
μ_i	Moyenne de la gaussienne i
σ_i	Ecart-type de la gaussienne i
I	Image de pondérations
S_b	Spectre du bulbe d'une galaxie
S_d	Spectre du disque d'une galaxie
S_t	Spectre total d'une galaxie
b/t	Rapport bulbe sur total d'une galaxie

5.2 Contexte astronomique

Les galaxies (figure 5.1) sont des objets astronomiques dont l'étude constitue à elle-seule une branche de l'astrophysique. En effet, ce sont au sein de ces objets que se forment les étoiles ainsi que les systèmes planétaires. Leur évolution, depuis leur naissance jusqu'au processus de formation stellaire qui s'y déroule, est un sujet d'étude essentiel faisant intervenir de nombreux champs d'investigation (physique, chimique...). Leur classification est une tâche essentielle permettant d'organiser, par la diversité des formes, la diversité dans les types de galaxies. C'est dans ce contexte que cette partie d'introduction astronomique prend sa place. Une première section présente une brève introduction à la physique des galaxies. Une première sous-section définit plus précisément les caractéristiques des galaxies. La deuxième sous-section traite de la spectroscopie et de l'apport d'information qu'elle fournit dans le cadre cosmologique. Un troisième point aborde le problème des corrections astronomiques qui se doit d'être pris en compte dans toute analyse spectrale. Enfin un résumé des problématiques ainsi que des méthodes de classification astronomique existantes est présenté dans la dernière sous-section. La deuxième section présente le logiciel GALICS permettant de simuler des champs de galaxies à partir d'un modèle cosmologique.

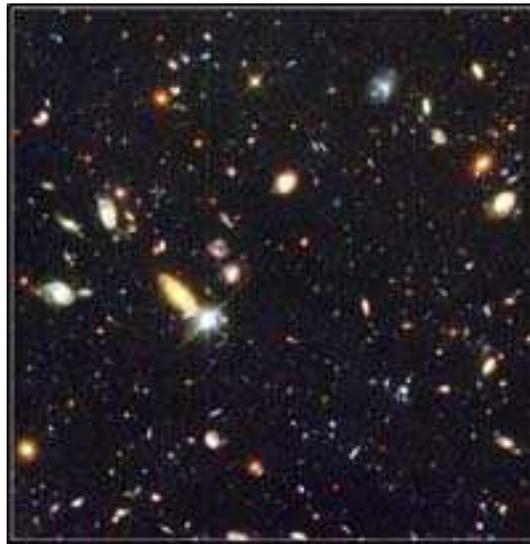


FIG. 5.1 – Amas de galaxies. Vue partielle du champ nord HDF

5.2.1 Introduction à la physique des galaxies

La physique des galaxies fait intervenir des notions astronomiques et physiques précises. Le processus de formation des galaxies, leur constitution, leur classification morphologique ainsi que les problématiques liées à leur nature sont des notions nécessaires afin de se livrer à une classification correcte de ces objets.

5.2.1.1 Définition et classification morphologique

Les galaxies sont des regroupements de plusieurs milliards d'étoiles, d'une masse de gaz au moins équivalente et de poussières. Elles sont très étendues (de 30 à 50 kPc) et peuvent se rassembler entre elles en définissant un amas de galaxies. Une galaxie est donc un vaste ensemble d'étoiles et de matière interstellaire (gaz, poussière) dont la cohésion est assurée par la gravitation. Une galaxie spirale ou lenticulaire est composée de deux éléments principaux présents en proportion variable :

- un disque aplati contenant beaucoup de matière interstellaire et renfermant des étoiles de tous les âges souvent organisé en une structure spirale barrée ou non ;
- un bulbe de forme sphéroïdale constitué pour l'essentiel d'une population d'étoiles vieilles (95% des étoiles).

Les galaxies montrant une grande diversité de formes dans le domaine optique, Hubble a proposé une classification basée sur les traits principaux de la morphologie et sur l'importance relative de leur bulbe et de leur disque (fig. 5.2) :

- les galaxies spirales (S) : bulbe sphérique au centre d'un disque. Celui-ci est confondu avec le plan de rotation autour du noyau et contient une structure spirale ;
- les galaxies spirales barrées (SB) : bulbe sphérique traversé par une barre d'étoiles, entouré de bras spiraux. La nomenclature des galaxies fait intervenir trois classes pour les types S et SB : de a (compacte) à c (déployée), la fraction de gaz augmentant entre les stades a et c . Elles peuvent être caractérisées morphologiquement par la finesse et l'ouverture des bras spiraux. Le gaz qu'elles contiennent constitue l'essentiel de leur masse et sert à produire des étoiles ;
- les galaxies elliptiques (E) : elles n'ont pas de brillance uniforme et ne présentent pas de structure apparente. Elles sont composées de nombreuses étoiles anciennes tournant lentement autour du centre et ne s'aplatissant donc pas en un disque ;
- les galaxies lenticulaires (SO) : elles sont pourvues d'un embryon de disque sans structure spirale et d'un bulbe central en forme d'ellipsoïde pincée aux extrémités ;
- les galaxies irrégulières (I) : elles ont une structure chaotique et sont en minorité. Elles sont principalement constituées de gaz.

La figure 5.3 présente un ensemble de 5 galaxies de types différents.

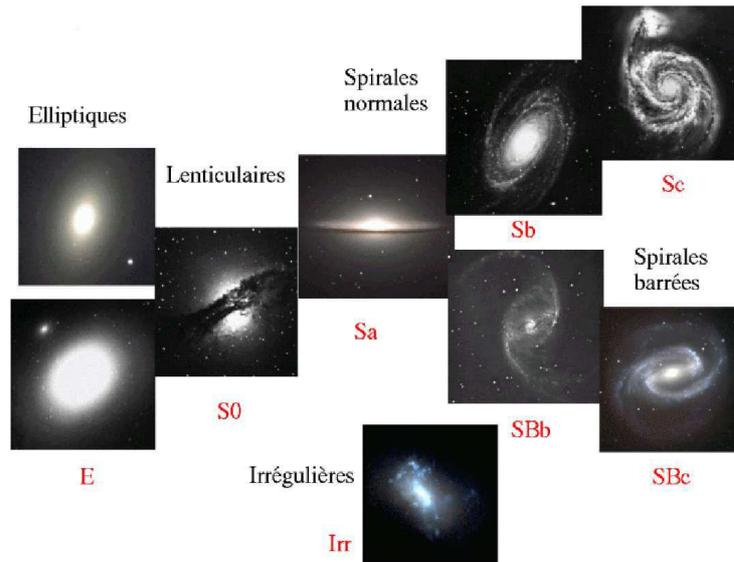


FIG. 5.2 – Classification de Hubble des galaxies.

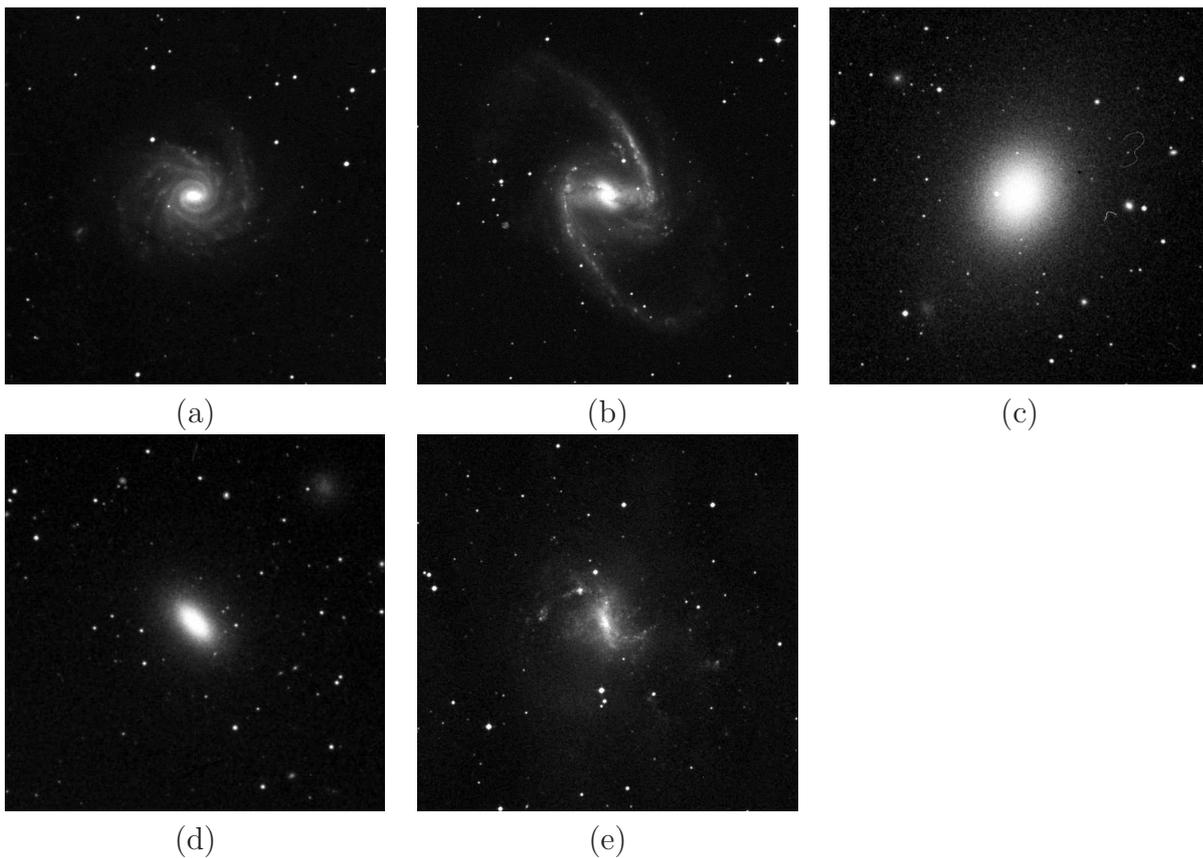


FIG. 5.3 – Différents types de galaxies dans le domaine du visible. (a) : galaxie spirale NGC1232. (b) : galaxie spirale barrée NGC1365. (c) : galaxie elliptique M49. (d) : galaxie lenticulaire NGC3377. (e) : galaxie irrégulière NGC1313

Une galaxie est issue d'un nuage ou d'un ensemble de nuages de gaz supposé au départ plus ou moins sphérique s'effondrant sur lui-même sous l'effet de la force gravitationnelle. Le gaz étant un système dissipatif (opérant dans un environnement qui échange de l'énergie), cet effondrement conduit alors à l'aplatissement de la galaxie. Les galaxies sont influencées par leur environnement (sous l'effet de la gravitation), cette influence se manifestant sur la forme de l'objet (effet de marée) ainsi que sur son comportement spectral (sursaut de formation stellaire). Chaque étoile de la galaxie est créée à partir d'un nuage de gaz dense et froid en contraction. Les plus massives sont les plus lumineuses et les plus chaudes (étoiles de type O et A, bleutées), une grande partie de leur rayonnement est dans l'UV (absorbé par l'atmosphère). Les interactions entre une galaxie et son environnement peuvent favoriser la naissance des étoiles (rencontre de galaxies par exemple) ou au contraire la défavoriser (gaz arraché de la galaxie).

La séquence de Hubble est basée sur des critères de forme (ainsi que sur des critères de variation de métallicité) mais le classement au sein de la classification de Hubble peut également s'effectuer sur une mesure de luminosité sachant que le profil d'intensité sur le grand axe de la galaxie est exponentiel décroissant pour le disque et suit une loi en $r^{\frac{1}{4}}$ pour le bulbe. Toutes ces informations permettent une caractérisation morphologique de l'objet. Pourtant celle-ci peut être délicate voir impossible dans certains cas : les galaxies lointaines par exemple ont une forme différente de celle que l'on connaît à courte distance. Leur classification est donc délicate car elles n'ont pas servi à construire la classification de Hubble. De plus, si la galaxie est vue parallèlement à la ligne de visée, les détails de la morphologie de l'objet n'apparaîtront pas et la classification sera difficile. Ces doutes peuvent être levés grâce à la spectroscopie qui consiste à utiliser l'information portée par un spectre de l'objet sur la formation stellaire. L'accès à ceux-ci permet alors une nouvelle vision des galaxies pouvant conduire à des classifications différentes des caractéristiques morphologiques des objets étudiés dans la gamme de l'optique.

5.2.1.2 Les éléments constitutifs du spectre

Le spectre d'une galaxie (ou de tout autre objet astronomique) contient toute l'information relative à la composition chimique de l'objet observé, ce qui renseigne sur l'histoire de sa formation stellaire. Un spectre est constitué d'une composante continue et d'un ensemble de raies d'émission et/ou d'absorption. Ces raies sont formées par l'interaction des atomes constitutifs de l'objet et des photons environnants. L'étude du spectre d'une galaxie permet d'obtenir des informations sur sa vitesse de rotation en mesurant le décalage des raies due à l'effet Doppler (effet global). L'information sur le décalage des raies permet d'obtenir une carte de vitesses de l'objet (petit décalage de raies à l'intérieur même de l'objet). Les caractéristiques des raies renseigne également sur l'abondance (profondeur de la raie) et la température de l'élément considéré (largeur de la raie). La comparaison de deux galaxies s'effectue via leurs spectres respectifs. En effet, si deux objets sont à une distance différente, alors le décalage des raies et le flux seront différents. Ce décalage revêt une grande importance dans l'étude spectrale des galaxies. C'est la raison pour laquelle la partie suivante détaille l'effet redshift (décalage vers le rouge des longueurs d'ondes dû à l'expansion de l'Univers) ainsi que les corrections à appliquer aux spectres des galaxies avant toute analyse.

5.2.1.3 Le décalage spectral z et les corrections associées

Le redshift cosmologique désigne le décalage vers les grandes longueurs d'ondes d'origine cosmologique. Ce redshift traduit l'expansion cosmologique et est donc un indicateur de distance pour définir l'éloignement des galaxies. Ainsi, en observant un champ de galaxies, chaque objet sera à un redshift différent (les objets n'étant pas tous à la même distance). Il convient donc, avant toute analyse spectrale, de décaler les spectres de chaque galaxie pour que ceux-ci aient le même z . Dans la pratique, le redshift n'est pas connu, il convient donc de l'estimer par des méthodes de corrélation entre le spectre observé et une base de spectres à redshift nul. Une fois estimé, le spectre est décalé de la manière suivante :

$$1 + z = \frac{\lambda}{\lambda_0} \quad (5.1)$$

où λ_0 est la longueur d'onde dans le référentiel du laboratoire.

L'émission d'une galaxie est donc observée à une longueur d'onde différente de celle à laquelle elle a été émise. Les propriétés d'émission doivent être comparées à la même longueur d'onde. La K -correction est une correction additionnelle qui permet de transformer les flux observés au *redshift* z à des flux correspondant à un *redshift* nul. Elle permet de compenser la perte d'énergie due au décalage des raies et à la modification de la largeur du filtre. La K -correction dépend donc directement de z et du filtre utilisé. Une dernière correction est appliquée sur les spectres de galaxies : la correction d'évolution \mathcal{E} reflète le fait que les objets n'évoluent pas tous de la même manière dans le temps.

Plusieurs logiciels permettent d'estimer le z ainsi que la K -correction des objets spécifique au filtre (HyperZ², LE PHARE³) et permettent ainsi la comparaison d'objets à des redshifts différents. Ces logiciels donnent également une estimation du type morphologique de l'objet (correspondant au type de la galaxie de référence dont la corrélation est la plus forte avec le spectre original). Il est à noter que ces corrections s'appliquent, dans ces logiciels, sur les spectres globaux de chaque objet et non sur les spectres d'une image où les objets sont résolus spatialement.

5.2.1.4 Problématique et classification existante

Dans une image multibande, on associe un spectre à chaque pixel. La classification spectrale de l'image va consister à trouver, dans les images, des régions de pixels ayant le même comportement spectral. Elle peut être combinée à une information morphologique pour raffiner la classification[4]. Le partage en classes doit s'effectuer selon des critères bien définis. On peut par exemple à l'aide d'une analyse spectrale déterminer la classe d'appartenance d'une galaxie dans la séquence de Hubble. Ainsi l'assignation d'une galaxie à son type ne se fera plus sur des critères morphologiques mais sur des critères spectraux. Il est alors possible de compléter la séquence de Hubble, des objets appartenant au même type pouvant avoir des comportements spectraux différents. Néanmoins, l'apparence d'un objet selon la bande spectrale, dans le cas d'une image multibande, est très variable. Ainsi dans l'UV, la galaxie apparaît par ses zones de formation stellaire (discontinuité de la structure) alors que dans l'infrarouge proche, on observe la structure globale de l'objet au travers des étoiles froides (figure 5.4).

²<http://webast.ast.obs-mip.fr/hyperz>

³http://www.loam.oamp.fr/arnouts/Le_PHARE.html

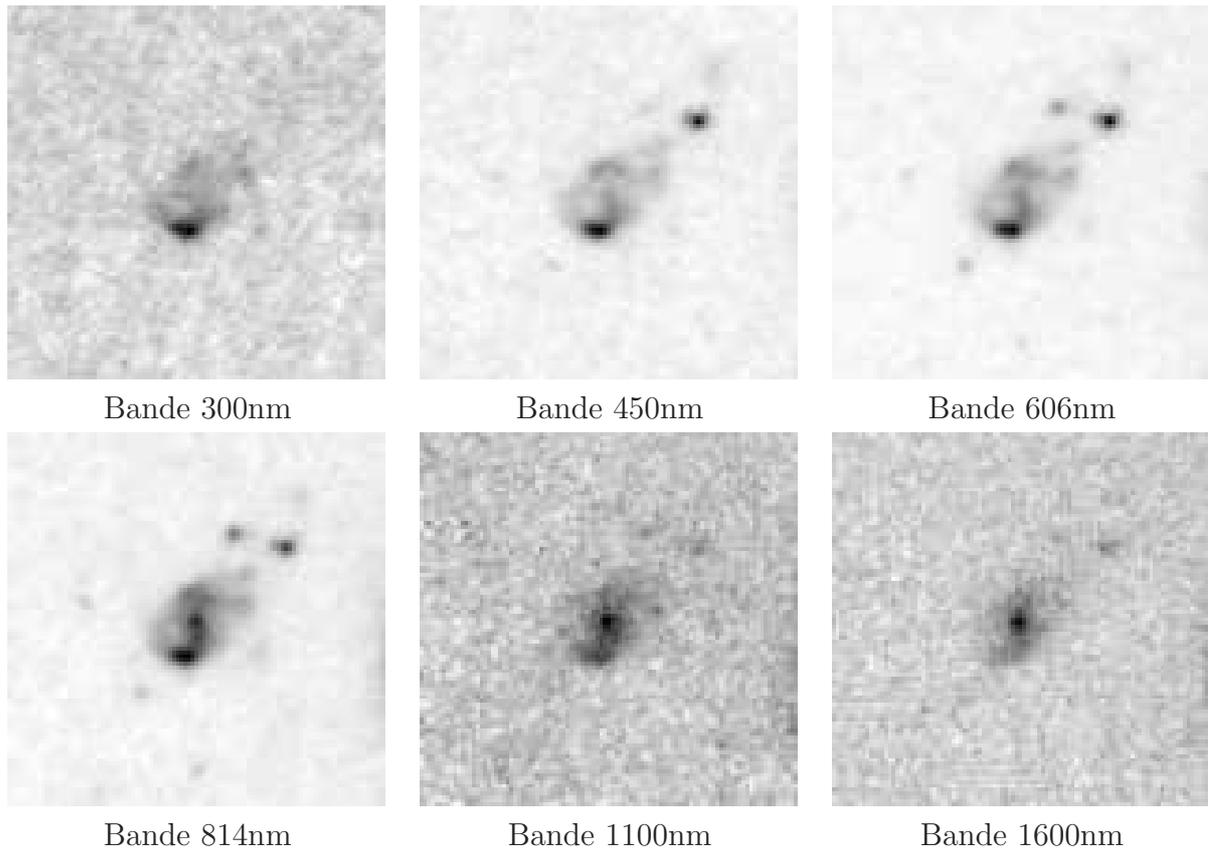


FIG. 5.4 – Galaxie de la collection d’images du Hubble Deep Field HDF-474 - 6 bandes. Taille 101×101 pixels. Pour chaque longueur d’onde, la galaxie présente des aspects différents : zones de formation stellaire dans l’UV et structure globale dans l’infrarouge proche

La classification des galaxies se heurte donc à différentes problématiques liées principalement au décalage spectral ainsi qu’au fait que les objets évoluent différemment. Typiquement, comment peut-on classer deux galaxies du même type mais à des redshift différents dans la même classe sachant que leur spectre sont différents? Comment, également, assigner une et une seule classe à une galaxie sachant que le profil d’intensité varie selon le rayon considéré? Ces deux problématiques peuvent être résolues d’une part en travaillant sur les spectres à z égaux (en les estimant sur les données réelles ou en utilisant un programme de simulation astronomique qui permet de contrôler le redshift de chacun des objets) et d’autre part à mettre en place une analyse spectrale couplée à une analyse spatiale du cube de données hyperspectrales. Les méthodes de classification existantes se base sur l’utilisation d’un spectre global par objet, par exemple, S. Laugier[67] a développé une méthode de classification des galaxies en se basant sur la variation d’un indice de concentration ente l’UV et le rouge (calculé sur le spectre global de la galaxie) en fonction de la symétrie de l’objet. Cet indice est calculé pour des galaxies de type connu puis comparé aux indices de galaxies de type inconnu. La classification issue du logiciel LE PHARE porte également sur les spectres globaux des objets. La nouveauté dans la méthode de classification spectromorphologique présentée ici réside dans l’utilisation d’un

cube de données où chaque objet est résolu spatialement, chaque galaxie étant représentée par un ensemble de spectres voisins spatialement.

5.2.2 Un univers simulé : GALICS

Le projet GALICS (Galaxies In Cosmological Simulations)[65][57] a pour but la simulation de champs de galaxies au sein d'un modèle cosmologique (figure 5.5).

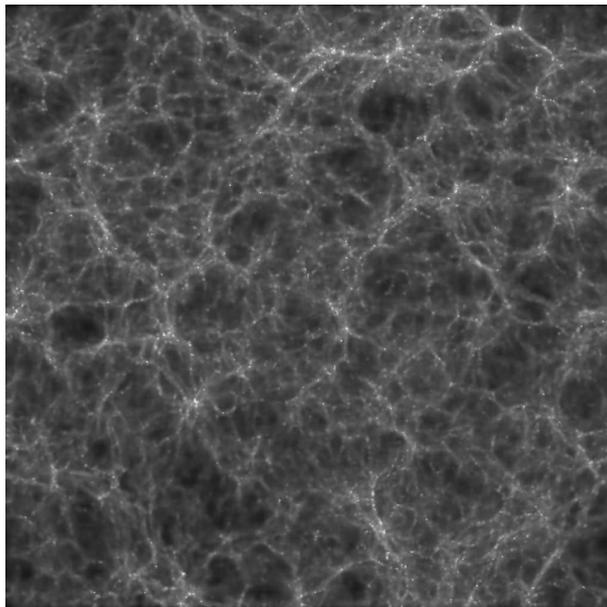


FIG. 5.5 – Image issue de la simulation Galics ($15Mpc$ de coté). Cette image correspond à l'état de la simulation du champ de galaxies à un instant donné ($z = 3$). Les filaments que l'on peut observer correspondent à de la matière noire. Les points brillants à leurs intersections sont des amas de galaxies en formation (accumulation de matière noire en présence de matière baryonique).

GALICS permet d'obtenir des cartes de pré-observations (à différentes longueurs d'ondes) qui sont des simulations d'observations de galaxies au travers de filtres connus sans le bruit lié à l'atmosphère ou à l'instrument (PSF). A partir du spectre global du bulbe et du disque de chaque galaxie, GALICS produit une liste de paramètres pour chaque longueur d'onde. GALICS permet donc d'avoir accès aux données suivantes :

- les cartes de pré-observations : la vérité-terrain ;
- le catalogue : c'est une base de données dans laquelle chaque objet est décrit par un ensemble de paramètres : coordonnées, magnitude, inclinaison, redshift, rapport bulbe sur total (directement lié au type morphologique de la galaxie[57])... Le bulbe d'une galaxie voit sa luminosité varier radialement selon une loi $r^{\frac{1}{4}}$ tandis que la luminosité du disque varie radialement selon une exponentielle décroissante. Ces deux lois ainsi que le catalogue sont utilisés par le logiciel SkyMaker⁴ permettant d'obtenir des observations bruitées telles qu'elles auraient pu l'être lors d'une

⁴<http://terapix.iap.fr/cplt/oldSite/soft/skymaker/>

observation classique (rajout de bruit, d'artefacts instrumentaux, de PSF). Chaque spectre pour chaque rayon de l'objet est donc une composition d'un spectre de bulbe et d'un spectre de disque (proportion en luminosité) dont la luminosité décroît en fonction de sa position dans la galaxie (bulbe ou disque). Nous pouvons donc observer deux variations spectrales dans les spectres de l'observation : une décroissance en luminosité et une composition bulbe-disque.

- la simulation permet d'avoir accès à des spectres de galaxies *rest-frame*, *i.e.* dans le référentiel de la galaxie (sans décalage spectral). Ainsi, dans un premier temps, les données utilisées sont à $z = 0$ permettant de s'affranchir de l'effet du décalage des raies. Ces spectres peuvent être convolués avec la réponse de filtres pour donner une liste de magnitude utilisable par Skymaker. L'étape de convolution va permettre d'échantillonner le spectre selon nos besoins. Le catalogue initial fourni avec les cartes de préobservations comporte une liste de 72 magnitudes par objet (associées à 72 filtres connus, certains couvrant une plage de longueur d'onde en partie commune) ;
- les spectres *observer-frame* pour chaque objet. Ces spectres sont donc dans le repère de l'observateur. Ils sont équivalents aux spectres *rest-frame* sauf qu'un décalage spectral leur a été appliqués.

La figure 5.6 résume clairement les résultats issus de GALICS.

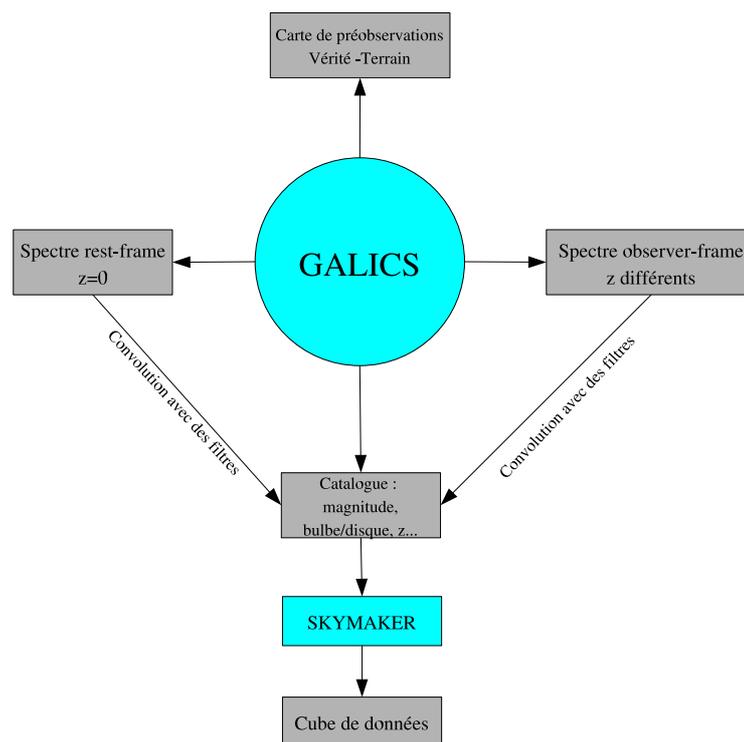


FIG. 5.6 – Résultats issus de GALICS

Les données simulées utilisées permettent donc de se livrer à une classification spectromorphologique des galaxies. D'une part le cube de données *rest-frame* (issu des spectres *rest-frame*) permet dans un premier temps de s'affranchir du décalage spectral et d'autre

part, le cube de données *observer-frame* permet dans un deuxième temps de travailler sur des données avec des décalages spectraux non nuls. Le but de la classification étant d'assigner un type morphologique à un objet, le rapport bulbe sur total (dépendant du type morphologique) présent dans le catalogue permet une comparaison entre le type estimé et le type réel. Cependant, dans le modèle GALICS, ce rapport bulbe sur total est un rapport de luminosité et non de surface. Il est donc délicat, à partir de la carte de segmentation, de retrouver ce rapport. Dans un premier temps, les résultats obtenus sur les simulations GALICS seront donc interprétés en fonction des classes obtenues par notre méthode et non par une comparaison du rapport bulbe/total. Dans le chapitre suivant, une méthode de projection des spectres de l'observation sur une base de spectres de référence associée à une segmentation permet d'effectuer une segmentation des données.

5.3 Réduction-Segmentation de cubes de données hyperspectraux

La classification consiste à créer des classes distinctes pour regrouper des entités, chaque classe agrégeant les entités par leurs caractéristiques communes. En astronomie, la classification porte sur des objets observables. Ce découpage en classe peut s'effectuer selon plusieurs critères différents : morphologique, spectral... Il est donc nécessaire de développer des outils permettant de classer les objets astronomiques. Afin d'effectuer cette classification, une étape de segmentation des observations est donc nécessaire. Une étape de réduction de données, préalable à la segmentation, est généralement appliquée sur de telles données hyperspectrales. Le but de cette réduction est de résumer toute l'information présente dans le cube de données original en un cube réduit de quelques bandes. Les approches basées sur des projections (analyse en composantes indépendantes[2], analyse en composantes principales[68], et leurs dérivées) ainsi que les mélanges de fonctions gaussiennes[10] sont très souvent utilisées dans l'étape de réduction. Néanmoins, ces méthodes ne sont pas appropriées dans le cas de distributions spectrales complexes : en effet, dans le cas de l'ACP, le critère de maximisation de la variance sur les composantes principales ne permet pas forcément de discriminer les données. D'autres méthodes d'analyses de données hyperspectrales permettent de déterminer les spectres purs (*end-members*) de l'observation[9, 44, 46] afin de décomposer chaque spectre comme une somme de spectres purs (spectre de sol, d'eau, de feuilles... dans le cas d'une image de télédétection). Ces méthodes sont généralement basées sur des techniques de projection et fréquemment utilisées dans le domaine de la télédétection ou de la détection de cibles. La méthode SAALT(spectral angle automatic cluster routine)[75] est une approche basée sur la méthode des K-Moyennes permettant de segmenter l'observation en fonction de critères spectraux (au travers d'une information d'angle spectral). Cependant, cette méthode ne prend pas en compte le voisinage spatial de chacun des spectres. Les méthodes dites de *spectral clustering*[26] consistent à diagonaliser une matrice de similarité (au lieu d'utiliser une distance traditionnelle, la mesure de similarité étant déduite au préalable d'une mesure de distance) obtenue sur l'observation hyperspectrale, puis à effectuer un partitionnement dans l'espace résultant de la projection des spectres de l'observation sur la base de vecteurs propres issue de la diagonalisation de la matrice de similarité. Ces méthodes restent cependant inadaptées dans certains cas, notamment à cause de la difficulté à

déterminer la qualité de la segmentation obtenue ainsi que la pertinence des nuages de points obtenus après projection[73]. Ces méthodes s'apparentent aux méthodes d'analyses en composantes principales par noyaux[77]. Enfin, une étape préliminaire à une réduction de données consiste à déterminer la dimension intrinsèque des données, *i.e.*, la taille minimale de l'espace de représentation des données. Ainsi pour un espace dont la dimension intrinsèque est 5, l'ajout de dimensions n'apportera aucune information supplémentaire pour des traitements ultérieurs. Les approches basées sur la méthode MDL (Minimum Descriptor Length) issue de la théorie de l'information consiste à découvrir les régularités présentes dans les observations[3, 49]. La découverte de ces régularités passe par la mesure de la longueur minimale avec laquelle les données peuvent être décrites. Chaque régularité ainsi déterminée peut être utilisée pour réduire les données et les décrire en utilisant un plus petit nombre de paramètres que celui requis par les données non réduites.

Dans ce chapitre nous proposons une nouvelle approche pour la réduction et la segmentation de cubes hyperspectraux en utilisant une approche spectrale. Dans une première section, nous présentons l'étape de réduction basée sur une projection spectrale. Chaque spectre de l'observation est ainsi projeté sur une base de spectres évolutive afin que chacun d'entre eux soit représenté par un ensemble de poids de projections. Comme la base de projection initiale n'est pas optimale, dans une deuxième partie, un algorithme de clustering de poids (Mean-shift[19]) est présenté afin de mettre à jour la base au fur et à mesure des itérations de l'algorithme. Une dernière étape de segmentation (algorithme des K-Moyennes ou segmentation markovienne par quadarbre) est alors effectuée dans le dernier espace de projection.

5.3.1 Projection des données

Les méthodes de projection sont généralement utilisées pour manipuler les données dans un espace différent. Les méthodes de poursuite de projection[38] plongent les données dans un espace maximisant un critère (par exemple, écart-type pour l'analyse en composantes principales, non-gaussianité pour l'analyse en composantes indépendantes). Le traitement des données, après projection, dépend fortement de la distribution des données originales. Ainsi, les résultats de ces projections peuvent souvent être inutilisables à cause d'un manque d'adaptation entre le modèle choisi pour discriminer les données et les données elles-mêmes (dans le cas de distributions complexes).

Soit Y une observation hyperspectrale, on désigne par Y_s le spectre de Y au site s . La projection de chaque spectre de l'image sur une base de référence $B = \{\beta_1 \cdots \beta_n\}$ de n spectres, va permettre de dégager la contribution relative de chacun des spectres de B présents dans l'observation. Le but est donc d'exprimer chaque spectre Y_s comme la somme pondérée par les coefficients $\omega_{si}, i \in [1, n]$ des spectres de la base (avec $\sum_i \omega_{si} = 1$). On peut donc écrire[58] :

$$\hat{Y}_s = \sum_{i=1}^n \omega_{si} \beta_i \quad (5.2)$$

et définir l'erreur quadratique de reconstruction globale :

$$\zeta = \sum_s (Y_s - \hat{Y}_s)^2 = \sum_s \left(Y_s - \sum_{i=1}^n \omega_{si} \beta_i \right)^2 \quad (5.3)$$

Avec $\sum_i \omega_i = 1$. On peut écrire l'erreur de reconstruction ζ_s en un site s sous la forme suivante :

$$\zeta_s = [Y_s - \sum_{i=1}^n \omega_{si} \beta_i]^2 = [\sum_{i=1}^n \omega_{si} (Y_s - \beta_i)]^2 = \sum_{i=1}^n \sum_{j=1}^n \omega_{si} \omega_{sj} \Gamma_{ij} \quad (5.4)$$

où Γ_{ij} est la matrice de covariance définit de la sorte :

$$\Gamma_{ij} = (Y_s - \beta_i)(Y_s - \beta_j)^T \quad (5.5)$$

Il convient de résoudre cette équation au sens des moindres carrés avec la contrainte $\sum_i \omega_{si} = 1$. On a donc :

$$\omega_{si} = \frac{\sum_{j=1}^n \Gamma_{ij}^{-1}}{\sum_{k=1}^n \sum_{l=1}^n \Gamma_{kl}^{-1}} \quad (5.6)$$

Chaque spectre Y_s est désormais défini par un vecteur de poids de dimension n .

La base de projection initiale peut être choisie de deux manières différentes :

- les n spectres de la base sont choisis au hasard dans les observations ;
- les n spectres sont choisis parmi un ensemble de spectres dont les caractéristiques sont connues (par exemple, en astronomie, un échantillon de la base de données de spectres de Kennicutt[54]). Cependant, il peut être délicat de construire une telle base. En effet, les spectres de la base et les spectres de l'image ne sont généralement pas échantillonnés de la même manière et le ré-échantillonnage des spectres de l'image peut conduire à des pertes de données significatives (petites raies par exemple).

Les comportements spectraux proches sont donc projetés dans un même sous-espace de l'espace \mathbb{R}^n . La base choisie initialement n'étant pas optimale, il est nécessaire de la faire évoluer en fonction de la distribution des poids de projection dans l'espace \mathbb{R}^n . Cette base B est donc amenée à être modifiée, tant en nombre de spectres qu'en forme de spectre. Pour cela, il est nécessaire d'obtenir les modes de la distribution des poids de projection en utilisant par exemple la méthode des Mean-Shift, leur nombre donnant une estimation du nombre de comportements spectraux dans les observations et leurs valeurs permettant de mettre à jour la base de projection.

5.3.2 La méthode des Mean-Shift

Les Mean-Shift[19] sont une méthode non-paramétrique permettant d'estimer les modes (maxima locaux) d'une densité de probabilité associée à une distribution de points dans un espace de dimension éventuellement élevée. Cette méthode est basée sur l'estimation du gradient de la densité de probabilité, celui-ci étant nul pour un mode. Le contexte théorique des Mean-Shift fait intervenir des notions d'estimation de densité par les noyaux de Parzen explicités dans la partie suivante. La méthode elle-même est décrite dans une seconde partie ainsi que son application à la méthode de classification proposée.

5.3.2.1 Les noyaux de Parzen pour l'estimation de la densité de probabilité $\hat{f}(x)$

De nombreuses méthodes permettent l'estimation d'une densité de probabilité associée à une distribution de points. La méthode par histogramme par exemple permet d'estimer

une densité en divisant l'espace de la distribution de points en n clusters et en calculant la fraction des points de la distribution appartenant à un même cluster. Néanmoins, la forme de la densité estimée est affectée par la taille et la position des clusters et peut présenter des discontinuités. En augmentant la dimensionnalité du problème, beaucoup de clusters resteront vides si le nombre d'échantillons n'est pas suffisant. L'utilisation de la méthode par histogramme est inadaptée pour notre cas où nous utilisons des données hyperspectrales. De manière générale, on peut écrire l'estimation non-paramétrique d'une densité de probabilité de la sorte :

$$\hat{f}(x) = \frac{k}{N.V_x} \quad (5.7)$$

où x est un point de la distribution, V_x le volume autour de x , N le cardinal de la distribution et k le nombre de points de la distribution appartenant à V_x .

Les méthodes de type k -plus proches voisins[21] permettent de déterminer V_x en fixant k mais ces méthodes sont peu robustes au bruit lorsque k est petit (lorsque k est choisi trop grand, la densité de probabilité estimée est lissée). Les méthodes d'estimation de densité par noyau nécessite de fixer V_x et de déterminer k à partir des données. La méthode des noyaux de Parzen[1] se propose d'estimer la densité de probabilité $\hat{f}(x)$ en utilisant une fonction particulière appelée noyau. On suppose que chaque point $x_i, i \in \{1..N\}, x_i \in \mathbb{R}^d$ de la distribution X produit une impulsion de forme K (le noyau) autour de lui. Supposons que cette impulsion soit un hypercube H de côté h centré sur x , de volume $V_x = h^d$ où d est le nombre de dimensions. On définit une fonction noyau $K(x)$ par :

$$K(x) = \begin{cases} 1 & \text{pour } \|x\| < \frac{1}{2} \\ 0 & \text{sinon} \end{cases} \quad (5.8)$$

Le nombre total de points présents dans l'hypercube est :

$$k = \sum_{i=1}^N K\left(\frac{\|x - x_i\|}{h}\right) \quad (5.9)$$

où

$$K\left(\frac{\|x - x_i\|}{h}\right) = \begin{cases} 1 & \text{si } x_i \in H \\ 0 & \text{sinon} \end{cases} \quad (5.10)$$

Le noyau de Parzen correspondant à cet hypercube unité est appelé fenêtre de Parzen. D'après l'équation 5.7 on peut écrire :

$$\hat{f}(x) = \frac{1}{Nh^d} \sum_{i=1}^N K\left(\frac{\|x - x_i\|}{h}\right) \quad (5.11)$$

Le choix de h (appelé paramètre de lissage ou largeur de bande) est crucial. En effet, plus h est élevé, plus la densité de probabilité estimée est "lissée" et certains modes locaux risquent d'être omis. Inversement, si h est trop petit, la densité de probabilité estimée laisse apparaître des modes inexistantes ou des modes associés au bruit dans le cas de données bruitées. Une première méthode d'estimation de h consiste à adapter la

largeur de bande au point x en fonction de la densité locale de points[18]. On peut donc écrire l'estimée de f sous la forme suivante :

$$\hat{f}(x) = \frac{1}{Nh(x)^d} \sum_{i=1}^N K\left(\frac{\|x - x_i\|}{h(x)}\right) \quad (5.12)$$

L'utilisation de cette estimation locale n'améliore cependant pas l'estimation de f par rapport à la méthode classique empirique[18]. De plus, le calcul de la densité locale autour de x fait intervenir une nouvelle hypersphère dont le rayon doit également être estimé. Une deuxième approche consiste à adapter le rayon de l'hypersphère en fonction des voisins x_i de x . On peut ainsi écrire[18] :

$$\hat{f}(x) = \frac{1}{N} \sum_{i=1}^N \frac{1}{h(x_i)^d} K\left(\frac{\|x - x_i\|}{h(x_i)}\right) \quad (5.13)$$

L'équation 5.13 nécessite cependant l'estimation du rayon h pour chaque x_i . Ce rayon peut être estimé de la sorte[18] :

$$h(x_i) = h_0 \left[\frac{\lambda}{f(x_i)} \right]^{1/2} \quad (5.14)$$

où h_0 est un rayon fixe préalablement déterminé, λ une constante influençant le lissage de la densité de probabilité f au point x_i . Deux nouveaux paramètres doivent donc être estimés : λ et h_0 . De plus, cette méthode nécessite une estimée de f (appelée fonction pilote) qui est obtenue à l'aide de la méthode des Mean-Shift classique. L'estimation de h dans ces deux méthodes nécessite donc l'introduction de nouveaux paramètres à estimer. Dans notre méthode de segmentation, nous utiliserons la méthode classique et le rayon h sera estimé empiriquement.

La fonction K présentée dans l'équation 5.8 est très contraignante. En effet, chacun des x_i appartenant à la même fenêtre a le même poids indépendamment de sa distance au point x pouvant rendre ainsi la densité estimée discontinue. L'utilisation de fonctions noyaux lisses permet de pallier ce problème, néanmoins la fonction K doit satisfaire les conditions suivantes :

- (1) $\forall x \in \mathbb{R}^d, K(x) \geq 0$ (positive)
- (2) $\exists S \in \mathbb{R}, \forall x \in \mathbb{R}^d, K(x) \leq S$ (bornée)
- (3) $\int_{\mathbb{R}^d} K(x) dx = 1$ (normalisée)
- (4) $\lim_{\|x\| \rightarrow +\infty} \|x\|^d K(x) = 0$ (décroissance rapide)

Voici quelques exemples de fonctions noyaux utilisées couramment :

- noyau gaussien (figure 5.7.a) : $(2\pi)^{-\frac{d}{2}} \exp(-\frac{1}{2}\|x\|^2)$;
- noyau d'Epanechnikov (figure 5.7.b) : $K_E(x)$;
- noyau exponentiel (figure 5.7.c) : $2^{-d} \exp(-\|x\|)$.

avec

$$K_E(x) = \begin{cases} \frac{1}{2} C_d^{-1} (d+2) (1 - \|x\|)^2 & \text{pour } \|x\| < 1 \\ 0 & \text{sinon} \end{cases} \quad (5.15)$$

où C_d est le volume de l'hypersphère unité de dimension d :

$$C_d = \begin{cases} \frac{1}{(\frac{d}{2})!} \pi^{\frac{d}{2}} & \text{si } d \text{ paire} \\ \frac{2^{\frac{d+1}{2}}}{d!!} \pi^{\frac{d-1}{2}} & \text{si } d \text{ impaire} \end{cases} \quad (5.16)$$

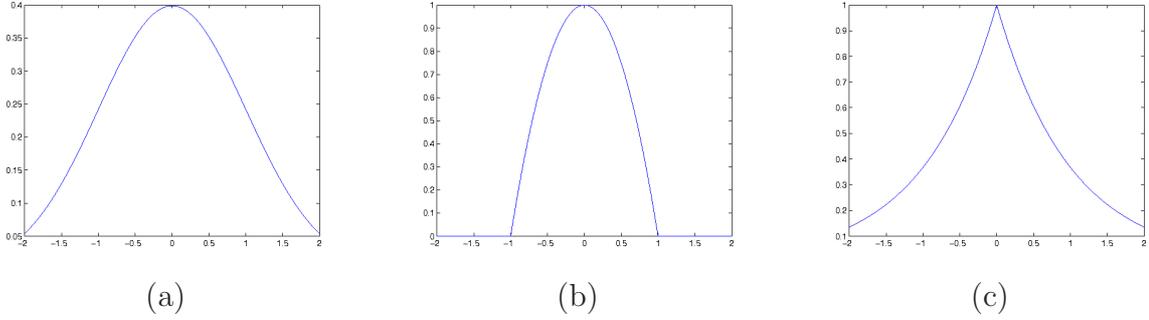


FIG. 5.7 – (a) : noyau gaussien. (b) : noyau d'Epanechnikov. (c) : noyau exponentiel

Le choix de l'expression du noyau est déterminé par la mesure de la qualité de l'estimation de la reconstruction \hat{f} de f . Cette qualité peut se mesurer en utilisant l'erreur quadratique moyenne intégrée (*EQMI* ou *MISE* pour *Mean Integrated Square Error criterion*) :

$$EQMI = E \left[\int_{\mathbb{R}^d} (\hat{f}(x) - f(x))^2 dx \right] = \int_{\mathbb{R}^d} E \left[\hat{f}(x) - f(x) \right]^2 dx = \int_{\mathbb{R}^d} EQM\{\hat{f}(x)\} dx \quad (5.17)$$

où *EQM* est l'erreur quadratique moyenne :

$$EQM\{\hat{f}(x)\} = E \left[\hat{f}(x) - f(x) \right]^2 \quad (5.18)$$

Le critère *MISE* (equation 5.17) est minimal dans le cas de l'utilisation du noyau d'Epanechnikov[19]. Ainsi, ce noyau permet une estimation de la densité d'un échantillon x_i en prenant en compte son voisinage compris dans une hypersphère de rayon h . L'utilisation de ce noyau dans l'estimation des modes d'une distribution de points est présentée dans la partie suivante.

5.3.2.2 La méthode des Mean-Shift

La détermination des modes d'une densité de probabilité à l'aide des Mean-Shift s'effectue sur une distribution de points X . Le principe de la méthode est de chercher à annuler le gradient de la densité de probabilité :

$$\nabla f(x) = 0 \quad (5.19)$$

La densité de probabilité $f(x)$ étant inconnue, il est impossible de calculer analytiquement le gradient de celle-ci. On remplace donc le calcul de l'estimation du gradient de la densité de probabilité par le calcul du gradient de la densité de probabilité estimée :

$$\hat{\nabla} f(x) \equiv \nabla \hat{f}(x) \quad (5.20)$$

En dérivant l'équation 5.11, on obtient :

$$\nabla \hat{f}(x) = \frac{1}{Nh^d} \sum_{i=1}^N \nabla K \left(\frac{(x_i - x)}{h} \right) \quad (5.21)$$

En utilisant le noyau d'Epanechnikov (équation 5.15), on écrit :

$$\nabla \hat{f}(x) = \frac{n_x}{Nh^d C_d} \frac{d+2}{h^2} \left[\frac{1}{n_x} \sum_{x_i \in S_h(x)} (x_i - x) \right] \quad (5.22)$$

où $S_h(x)$ est l'hypersphère de rayon h , de volume $h^d C_d$ centrée en x et contenant n_x points de la distribution.

Le dernier terme de l'équation 5.22 est appelé vecteur Mean-Shift :

$$M_h(x) = \frac{1}{n_x} \sum_{x_i \in S_h(x)} (x_i - x) = \left(\frac{1}{n_x} \sum_{x_i \in S_h(x)} x_i \right) - x \quad (5.23)$$

Il est une estimation du gradient de la densité de probabilité estimée : $M_h(x) \equiv \nabla \hat{f}(x)$, pointant dans la direction de la plus grande pente de la densité de probabilité. Le vecteur Mean-Shift correspond à la moyenne des écarts entre le point x et ses voisins dans l'hypersphère.

L'algorithme des Mean-Shift est une procédure itérative. On peut à partir de chaque point x_i de la distribution, déterminer son mode de convergence. Ainsi, à chaque point de la distribution est associé un mode, celui-ci pouvant être identique ou différent des modes précédemment déterminés. La procédure itérative des meanshift est résumée dans l'algorithme ci-après. En utilisant la méthode des Mean-Shift sur la distribution des poids de

Algorithme 5.1 Procédure Mean-Shift, la procédure est répétée pour chaque $x \in X$.

Entrée: x : Vecteur de dimension d appartenant à la distribution de points X
 h : Rayon de l'hypersphère

- $m \leftarrow x$

Tant que m est différent à chaque itération **Faire**

- Calculer $M_h(m)$ à l'aide de l'équation 5.23
- $m \leftarrow m + M_h(m)$

Fin Tant que

- m est le mode associé à x
-

projection des spectres, les modes de chaque classe spectrale sont obtenus. Ainsi, l'algorithme permet une première classification spectrale (deux vecteurs de pondération et leur spectre respectif étant voisins dans \mathbb{R}^n ne signifie pas que les deux spectres soient voisins dans l'image) conduisant à une carte de segmentation basée sur des critères spectraux (les vecteurs de pondération convergeant vers le même mode sont assignés à la même classe spectrale). Chaque mode ainsi déterminé représente un comportement spectral observé (et donc une classe) dans le cube de données hyperspectrales. La base de spectres initiale n'étant pas forcément optimale, il est nécessaire de la mettre à jour au cours de

l'algorithme. Par exemple si la base comporte trois spectres alors qu'il y a quatre comportements spectraux différents dans l'image, la projection des données va générer quatre nuages de points. Les Mean-Shift détecteront donc quatre modes dont celui correspondant au spectre manquant dans la base. En utilisant l'ensemble des spectres associés aux modes, une nouvelle base est formée et réinjectée dans l'algorithme, celui-ci s'arrêtant lorsque la base est identique d'une itération à l'autre, lorsque le nombre de modes devient constant ou qu'il atteint une certaine limite fixée par l'astronome. Il convient de remarquer que la méthode des Mean-Shift est une méthode statistique (le calcul du vecteur Mean-Shift faisant intervenir une moyenne). Il est donc nécessaire d'avoir un certain nombre de pondérations (et donc de spectres) à disposition pour l'estimation du gradient. Cela ne pose généralement pas de problème en imagerie astronomique où les images sont de taille suffisante. A l'issue des étapes de projections et de mise à jour de la base B , on obtient les données suivantes :

- images des pondérations : une image de pondération I_i correspond aux poids de projections des spectres originaux sur un spectre β_i de la base. Ainsi pour une base de projection composée de cinq spectres, cinq images de pondérations seront obtenues ;
- nombre de modes : ce nombre correspond au nombre de comportements spectraux différents présents dans l'image. Il est donc une estimation du nombre de classes spectrales des observations ;
- base de spectres finale : cette base est composée des spectres caractéristiques présents dans les observations.

Selon le type d'études effectuées, la méthode de projection peut se révéler inadaptée. En effet, cette méthode de projection n'est pas invariante en intensité. Ainsi deux spectres de comportements spectraux identiques mais à un décalage en luminosité près ne seront pas projetés sur le même point dans l'espace de projection. Des modes de luminosité apparaîtront alors lors de l'étape des Mean-Shift. Dans le cas où l'astronome voudrait se focaliser uniquement sur les différences spectrales (et non en luminosité), il convient de mettre en place une mesure entre vecteurs invariante en intensité. L'angle spectral[75] (*SAM : Spectral Angle Mapper*) α possède cette propriété d'invariance :

$$\alpha(\beta_i, Y_s) = \arccos \frac{\langle \beta_i, Y_s \rangle}{|\beta_i| |Y_s|} \quad (5.24)$$

Ainsi, les spectres seront discriminés uniquement en fonction de leur comportement spectral : $\alpha(\beta_i, Y_s) = \alpha(\beta_i, Y_s + c)$. Dans le cas où l'astronome retient une telle approche, l'angle spectral remplace tout simplement l'étape de projection dans l'algorithme, les angles entre les spectres de l'image et les spectres de la base étant calculés. L'espace obtenu sera donc un espace d'angles et non plus de poids de projection.

Les images de poids de projection ou d'angles sont finalement segmentées de deux manières différentes selon le nombre b d'images de poids/angles :

- $b < 10$: une segmentation par quadarbre markovien est effectuée. Celle-ci va permettre d'ajouter une régularisation spatiale dans la carte de segmentation finale ;
- $b > 10$: lorsque le nombre de bandes dépasse 10, l'approche markovienne est inadaptée. Une segmentation par algorithme des K-Moyennes est effectuée, aucune régularisation spatiale n'est alors réalisée.

Le nombre de classes K dans ces méthodes de segmentation peut être obtenu de deux

manières différentes :

- K est fixé *a priori* par l'astronome en fonction du type d'études à mener ;
- K correspond au nombre de modes détectés dans le dernier espace de projection (nombre de comportements spectraux différents). Si le nombre de classes devient très grand, une étape de fusion de classes peut être effectuée sur la carte de segmentation, en regroupant les classes dont la corrélation des spectres moyens est la plus proche. L'utilisateur peut ainsi fixer un nombre de classes maximal.

La figure 5.8 présente la chaîne de traitements complète de la méthode de classification proposée.

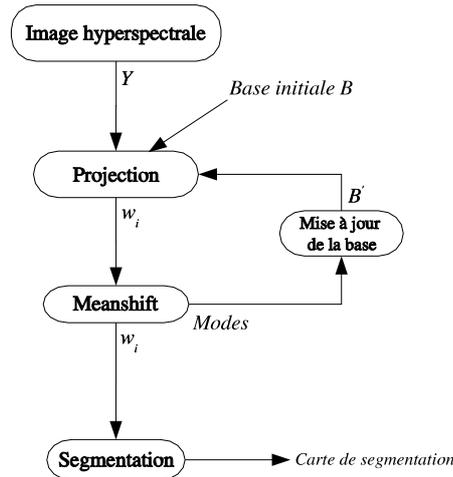


FIG. 5.8 – Schéma récapitulatif de la méthode de classification présentée

L'approche présentée ici est validée, dans un premier temps sur des champs de galaxies hyperspectrales simulées par GALICS ($z = 0$), fournis par J. Blaizot, puis sur une image hyperspectrale issue du domaine de la télédétection fournie par F. Nerry. Enfin, la méthode est appliquée sur un cube de données simulé fourni par Ch. Pichon (IAP).

5.4 Résultats

Galics

Les données de synthèse utilisées pour valider notre méthode sur des images astronomiques sont issues de GALICS. A partir des spectres rest-frame ($z = 0$) d'un ensemble de galaxies, on simule une observation (avec Skymaker) où les objets sont résolus spatialement. Initialement, un objet est caractérisé par deux ou trois spectres :

- un spectre du bulbe (S_b) ;
- un spectre du disque (S_d) ;
- un spectre de raies (*burst* : sursaut de formations stellaires).

Si un objet ne comporte pas de spectre de bulbe (resp. disque), alors il sera considéré comme étant une galaxie composée uniquement d'un disque (resp. bulbe). Le spectre total

d'une galaxie est défini de la sorte : $S_t = S_b + S_d$. Le rapport bulbe/total de luminosité est également défini comme suit : $b/t = S_b/S_t$, ce rapport étant différent pour chaque longueur d'onde. A partir du spectre total et du rapport b/t , on crée un ensemble de catalogues (un pour chaque longueur d'onde) contenant pour chaque objet un ensemble de paramètres le décrivant. Le logiciel Skymaker permet alors, à partir de ces paramètres, de générer un ensemble de cartes monochromatiques constituant un cube de données hyperspectral. Dans ce cube de données, une galaxie sera composée d'un bulbe central et d'un disque périphérique. En allant du centre de la galaxie (centre du bulbe $r = 0$) vers l'extérieur de l'objet (périphérie du disque) les spectres successifs sont une combinaison linéaire du spectre du bulbe et du spectre du disque de l'objet avec une décroissance en luminosité selon les composantes. On peut donc écrire le spectre de l'objet dans l'image à un rayon r donné de la sorte : $a_{1r}S_b + a_{2r}S_d$. Ainsi, au centre de la galaxie, le comportement spectral du bulbe sera prépondérant alors qu'à sa périphérie c'est le disque qui le sera.

Le cube de données simulé ici comporte 11 galaxies (de rapports b/t différents) et est de taille $128 \times 128 \times 128$ pixels. La figure 5.9 présente quelques bandes du cube de données. Après application de notre méthode sur ce cube, la carte de segmentation obtenue par la méthode de projection (figure 5.10) est composée de 54 classes. La figure 5.11 présente quelques comportements spectraux principaux détectés dans le cube de données. Les résultats obtenus ont été validés par un expert.



FIG. 5.9 – Deux bandes du cube hyperspectral simulé avec Skymaker (sans bruit, largeur à mi-hauteur de la PSF : 0.9 arcsec). La luminosité des objets décroît radialement et chaque objet présente une variation de flux en fonction de la longueur d'onde.

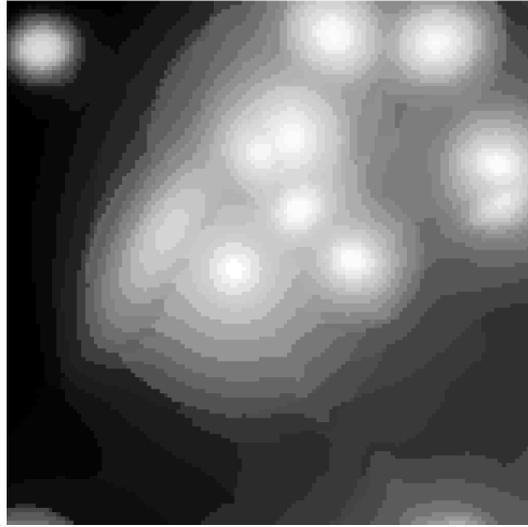


FIG. 5.10 – Carte de segmentation (K-Moyennes 54 classes). Chaque objet est composé d'un ensemble de classes. Chaque ensemble différent correspond à des objets de types différents. Pour un objet donné, un ou deux comportements spectraux sont détectés (correspondant aux composantes bulbe et/ou disque). A l'intérieur d'un objet, l'ensemble de classes est composé d'une séquence de classes de luminosité et d'une combinaison spectrale bulbe/disque. Chaque spectre moyen de classe change radialement à l'intérieur d'un objet : au centre de l'objet, le spectre moyen correspond à un spectre de bulbe alors qu'à la périphérie de l'objet, ce spectre correspond à un spectre de disque. Les spectres moyens intermédiaires sont composés d'une combinaison linéaire des spectres du disque et du bulbe. Ce résultat a été validé à partir du catalogue GALICS en comparant les spectres globaux du bulbe et du disque de chaque galaxie avec les spectres moyens de classes correspondant.

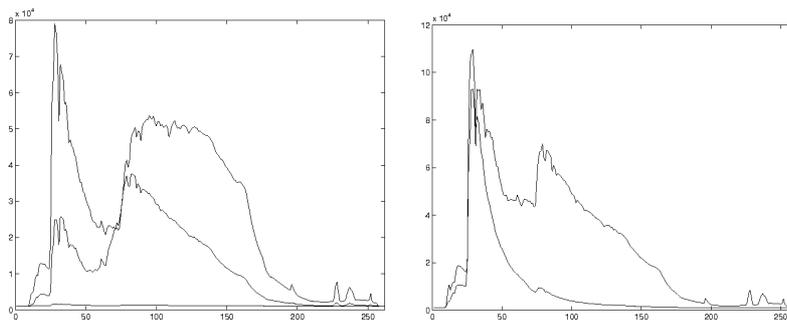


FIG. 5.11 – Cinq spectres de la base finale contenant au total 54 comportements spectraux différents. Ces cinq comportements spectraux sont caractéristiques du type des différents objets. Ce sont des spectres situés au centre et à la périphérie de galaxies. Plusieurs des autres spectres de la base sont des combinaisons linéaires de ces 5 spectres (variations en luminosité et composition bulbe-disque). Pour réduire le nombre de classes, une étape de fusion de classes peut être effectuée sur la carte de segmentation, en regroupant les classes dont la luminosité des spectres moyens est proches.

Le résultat suivant obtenu sur le même jeu de données que précédemment (figure 5.9) compare les résultats de segmentation obtenus par la méthode de projection puis par la méthode par angles spectraux. Les paramètres de l'algorithme sont les mêmes dans les deux cas ($h = 0.2$) et le nombre d'itérations a été fixé à 2 (au delà, l'algorithme converge et le nombre de spectres dans la base reste constant). La figure 5.12 présente les deux cartes de segmentation obtenues.

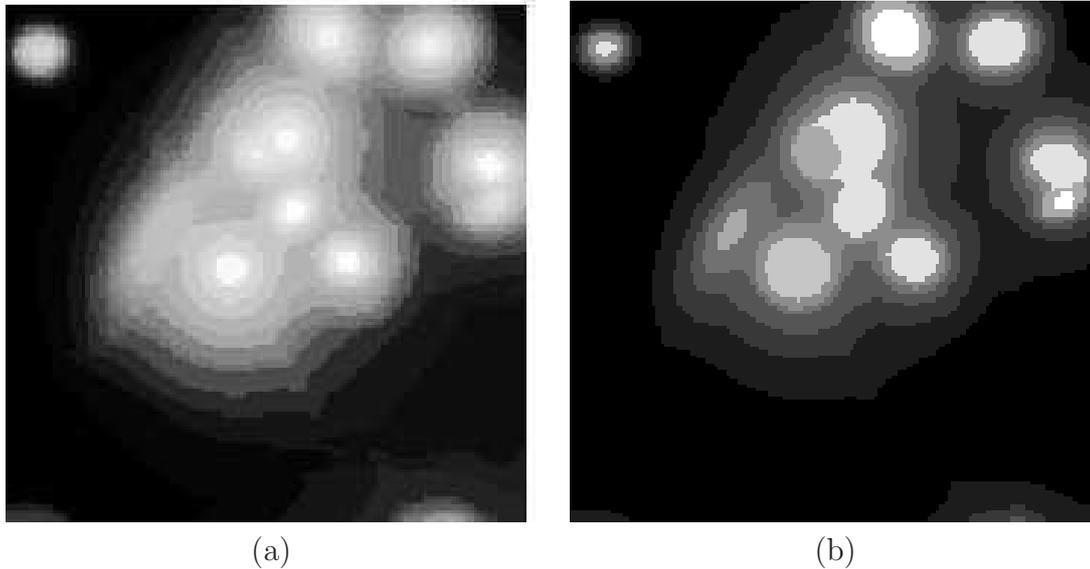


FIG. 5.12 – (a) : carte de segmentation par méthode de projection (34 classes). (b) : carte de segmentation par méthode d'angle spectral (10 classes). En comparant (a) et (b) on peut remarquer que le nombre de classes en (b) est beaucoup plus restreint qu'en (a). En effet, la méthode par projection fait ressortir des classes de luminosité en plus des classes spectrales. Comme la luminosité varie radialement pour chaque objet, la carte de segmentation (a) contient de nombreuses classes pour chacun des objets. Par contre, en (b), l'utilisation d'une mesure invariante en luminosité permet de se focaliser sur les comportements spectraux. Chaque objet n'est donc plus composé que de quelques classes représentatives de son comportement spectral. On voit ainsi apparaître une classe centrale correspondant à un bulbe et une classe périphérique correspondant à un disque pour chaque objet.

La figure 5.13 présente une carte de segmentation des observations Galics (figure 5.9) obtenue par la méthode des angles spectraux. Les images d'angles ont été segmentées en 20 classes alors que l'algorithme en avait déterminé automatiquement 10 (figure 5.12.b).



FIG. 5.13 – Carte de segmentation 20 classes des observations Galics (figure 5.9). On peut comparer ce résultat, obtenu en “forçant” le nombre de classes à 20 avec le résultat obtenu figure 5.12.b pour lequel l'algorithme avait automatiquement estimé 10 classes. On peut remarquer que les 10 classes supplémentaires ont plutôt été rajoutées à la périphérie des objets. En effet, en ajoutant 10 classes lors du processus de segmentation nous avons “forcé” l'algorithme de segmentation à trouver 20 classes là où le nombre de classes spectrales estimées à l'issue des Mean-Shift est de 10. L'algorithme de segmentation va donc sur-segmenter les classes déjà présentes figure 5.12.b.

Cube hyperspectral issu du domaine de la télédétection

Le résultat suivant a été obtenu sur un cube hyperspectral issu du domaine de la télédétection ($512 \times 512 \times 80$ pixels). Il a été réduit à l'aide de la méthode par angle spectral puis les bandes réduites ont été segmentées par quadarbre markovien introduisant ainsi un *a priori* spatial dans la carte de segmentation. Le nombre de classes, $K = 12$, a été déterminé par un expert en télédétection. La figure 5.14 présente une bande de l'observation et la figure 5.15 présente la carte de segmentation obtenue et comparée avec la vérité-terrain.

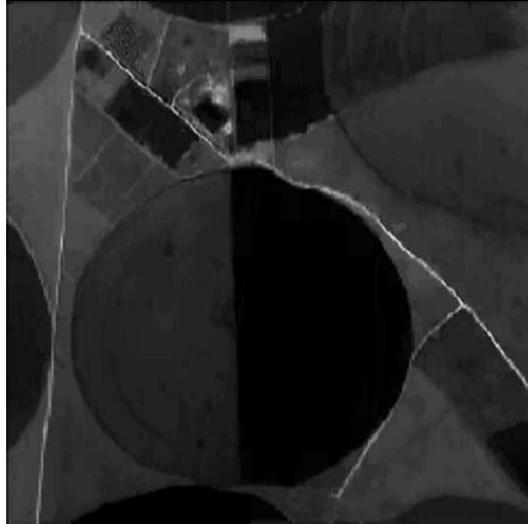


FIG. 5.14 – Observation - AHS (Airborne Hyperspectral Scanner) L1B - Projet SEN2FLEX. Résolution au sol : 2–3m. Cette observation est constituée d’un ensemble de champs ronds mis en jachère. Une route ainsi qu’un bassin d’eau sont également présents dans l’observation.

Image simulée hyperspectrale de l’Institut d’Astrophysique de Paris

L’image suivante ($64 \times 64 \times 540$) a été fournie par Ch. Pichon et E. Thiebauld de l’Institut d’Astrophysique de Paris. Elle représente une galaxie spirale composée d’un bras, d’un bulbe, d’un disque ainsi que d’un AGN (noyau actif de galaxie) au centre. Chacune de ces composantes présente un comportement spectral propre. De plus, un ensemble de 30 étoiles possédant des comportements spectraux différents, a été rajouté à l’observation afin de valider le pouvoir discriminatoire de notre méthode. La galaxie de ce cube est simulée en utilisant un modèle géométrique : ellipse, spirale... L’intensité des spectres des observations varie en fonction de la longueur d’onde et les raies d’émission/absorption des spectres de la galaxie sont légèrement décalés en fonction de leur distance au centre de l’objet. L’application de notre méthode sur ce cube doit permettre de dégager les principaux comportements spectraux présents dans la galaxie (AGN central, bulbe, bras, disque) et de discriminer également les différentes étoiles présentes en périphérie et au centre de la galaxie. La figure 5.16 présente deux bandes parmi les 540 de l’observation. La figure 5.17 montre d’une part la carte de segmentation spectrale (à l’issue des Mean-Shift) et d’autre part la carte de segmentation issue de l’algorithme des K-Moyennes. Ce résultat a été obtenu à l’aide de la méthode par angle spectral et a été validé par un expert.

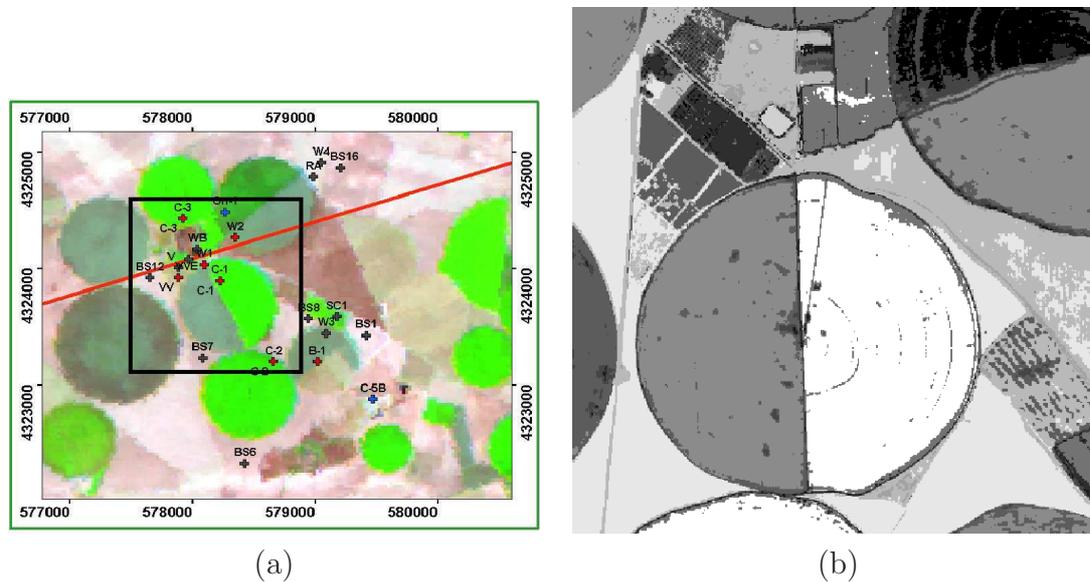


FIG. 5.15 – (a) : vérité-terrain. Cette carte a été obtenue par un ensemble de mesures effectuées directement sur le terrain. Chaque zone de même couleur correspond à des zones de cultures identiques (et donc de comportements spectraux identiques). La zone étudiée ici est incluse dans le carré noir et est légèrement tournée dans le sens des aiguilles d'une montre. (b) : carte de segmentation obtenue sur le quadarbre markovien (12 classes). En comparant la vérité-terrain (a) à la carte de segmentation (b), on peut remarquer que les champs de même couleur en (a) ont la même classe en (b). C'est notamment le cas du demi-cercle blanc au centre et du bout de cercle également en blanc en bas de l'image (qui se retrouvent en vert dans la vérité-terrain). Le cercle incomplet en haut à droite est également bien segmenté. Le bassin d'eau présent en haut au dessus du champ central (petite zone rectangulaire gris clair dans la carte de segmentation) a bien été discriminé également ainsi que les routes. Cependant, le cercle tronqué sur le bord supérieur de l'image (b) (en vert en (a)) devrait appartenir à la même classe que la partie blanche du champ central. Il en est de même pour les champs rectangulaires en haut au milieu de la carte (présence d'un liseré de classe blanche à l'intérieur). L'étude des spectres de ces deux zones montrent une très légère différence spectrale (raie d'émission légèrement plus importante dans le cercle tronqué). De plus, comme le champ tronqué n'est pas complet dans l'image, le peu de spectres de celui-ci à disposition reste très peu représentatif du comportement spectral global de ce champ. La vérité-terrain n'est pas échantillonnée de la même manière que la carte de segmentation : le pourcentage de classification n'est donc pas accessible. Cependant, ce résultat a été validé par un expert en télédétection.

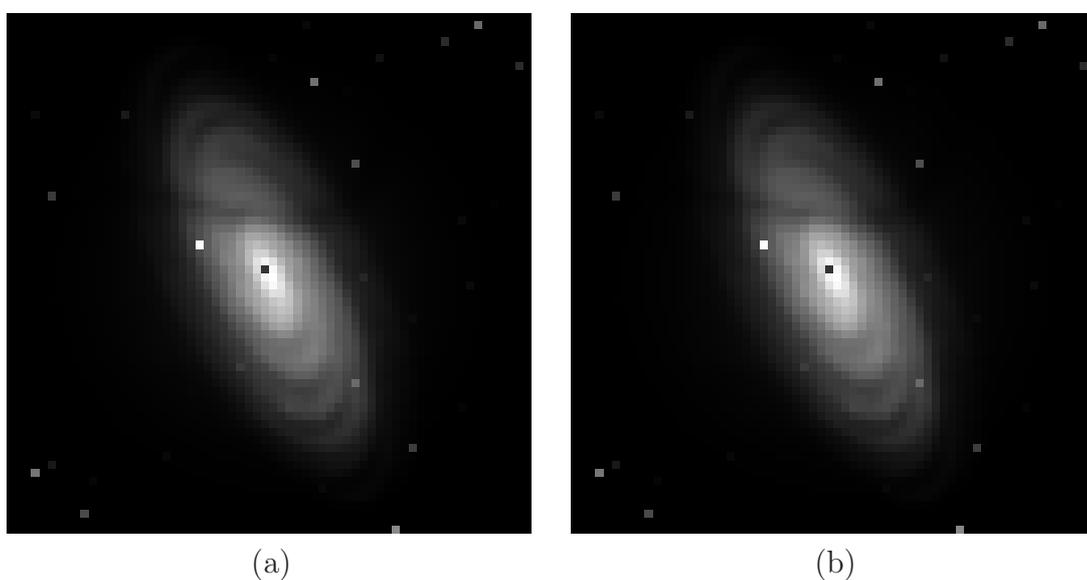


FIG. 5.16 – Deux bandes de l’observation hyperspectrale (taille : $64 \times 64 \times 540$). On distingue notamment la galaxie au centre occupant la majeure partie de l’image ainsi que les étoiles parsemées autour et dans la galaxie (objets ponctuels). Le pixel noir central correspond à l’AGN.

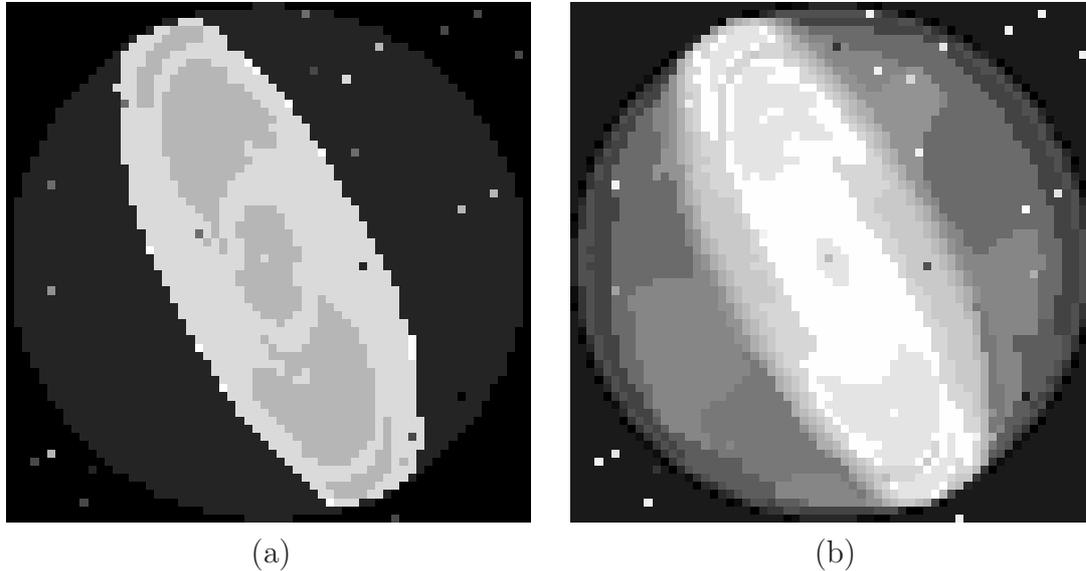


FIG. 5.17 – (a) : carte de segmentation spectrale à l'issue des Mean-shift (9 classes après convergence de l'algorithme) : tous les pixels convergeant vers le même mode appartiennent à la même classe. (b) : carte de segmentation à l'issue des K-Moyennes (20 classes fixées). On remarque en (a) que les principaux comportements spectraux ont bien été retrouvés : quasar au centre (point central), bulbe autour du quasar, disque, structure spirale, étoiles. A chaque classe dans (a) correspond un comportement spectral dans la base de projection finale. On a donc extrait les comportements spectraux caractéristiques de l'observation. On peut également remarquer en (a) (et en (b) également) que la zone centrale du bulbe (autour de l'AGN) est de la même classe que les deux zones dans les bras spiraux (en haut et en bas de l'image). Cela provient tout simplement du fait que le bulbe contient beaucoup de gaz et présente une formation stellaire intense (*burst* : sursaut de formation stellaire). Son comportement est donc identique à celui d'un disque. La carte de segmentation (b) comporte 20 classes. On peut remarquer, par rapport à (a), que les K-Moyennes ont introduit, au travers des 10 classes supplémentaires, quelques classes de luminosité en périphérie de la galaxie. Cependant, toutes les composantes sont également discriminées correctement. Pour ce cube de données, la carte de segmentation va permettre à l'astronome de se focaliser sur les composantes ainsi dégagées pour, par exemple, calculer les différences minimales de position des raies d'émission et d'absorption dans les spectres d'une même classe afin d'obtenir une carte du champ de vitesse de la galaxie. La carte de segmentation simplifie ainsi l'interprétation et les études faites par l'astronome.

5.5 Conclusion

L'imagerie hyperspectrale astronomique apporte une nouvelle vision sur les objets observés à l'aide de capteur mono ou multispectraux. L'accès à un spectre finement échantillonné permet de mettre en valeur les propriétés physiques et chimiques des objets considérés. Cependant, ces grandes masses de données se heurtent rapidement au problème d'interprétation. En effet, la manipulation et le traitement de tels cubes sont confrontés à la complexité du problème qui augmente avec le nombre de bandes de l'observation. La segmentation hyperspectrale permet à l'astronome de disposer d'une carte dans laquelle chaque classe est caractéristique d'un comportement spectral. L'astronome peut ainsi étudier précisément une zone d'intérêt, par exemple, en calculant des dispersions de vitesse intra-classe. Les méthodes de segmentation standards se heurtant rapidement au problème de dimension des données, notre méthode de segmentation spectrale permet d'éviter cette "malédiction" et de proposer un partitionnement de l'observation en classe spectrale. L'utilisation d'une projection préalable à la segmentation permet de travailler dans un espace réduit conservant toute la richesse et la différenciation spectrale des observations. Cette projection étant dépendante de l'intensité des spectres de l'observation, nous proposons également une réduction basée sur une mesure d'angle spectral invariante en intensité. Ainsi l'astronome peut, dans notre algorithme, choisir le type de réduction, en fonction de la problématique intrinsèque de son observation. La construction d'une base de spectres, à l'aide des Mean-Shift dans l'espace réduit, au fur et à mesure des itérations de l'algorithme permet de dégager les principaux comportements spectraux présents dans l'observation. Puis, les images réduites finales sont segmentées en utilisant une approche markovienne par quadarbre lorsque le nombre de bandes réduites est inférieur à 10 ou par algorithme des K-Moyennes lorsque ce nombre est supérieur à la dizaine. L'utilisation d'une approche markovienne permet d'introduire une régularisation spatiale de la carte de segmentation par la prise en compte du voisinage de chacun des spectres.

La méthode proposée est d'une grande souplesse pour l'astronome. Elle lui permet d'utiliser sa propre base de spectres dans le cas où les spectres de l'observation sont connus. De plus, l'algorithme peut fonctionner de manière non-supervisée en estimant le nombre de classes en fonction du nombre de comportements spectraux détectés ou alors de manière supervisée, le nombre de classes étant connu *a priori*. Cette méthode a été validée sur plusieurs jeux de données simulées ainsi que sur une image hyperspectrale issue du domaine de la télédétection.

Cependant, il serait nécessaire d'offrir une estimation du rayon h des Mean-Shift automatisée afin de proposer un algorithme totalement non supervisé à la communauté astronomique. Pour l'instant, celui-ci est fixé empiriquement et, lorsque le nombre de modes augmente fortement (du à un choix de rayon trop petit), l'algorithme fusionne les spectres de la base les plus corrélés. Il serait également judicieux de proposer une régularisation spatiale lorsque le nombre de bandes de l'observation réduite dépasse la dizaine. Enfin, une dernière modification pourrait porter sur l'optimisation algorithmique de l'étape des Mean-Shift. En effet, l'algorithme des Mean-Shift est responsable de 80% du temps de calcul⁵. Les Mean-Shift consistent à calculer un très grand nombre de fois des distances entre un grand nombre de points dans un espace de dimension éventuellement élevée. Cette étape de calcul de distance est très coûteuse en temps de calcul. Le programme FAMS

⁵pour une image $128 \times 128 \times 200$, une itération de l'algorithme prend 4 minutes sur un PC standard

(Fast Adaptive Mean Shift)[6] a été développé en utilisant un algorithme de recherche de voisins dans un espace de grande dimension. Il pourrait être intéressant d'adapter cette algorithme afin de l'intégrer dans notre méthode de réduction-segmentation. L'algorithme des Mean-Shift se prêterait également parfaitement à une parallélisation. Cependant, le temps de calcul est très peu dépendant du nombre de bandes spectrales et est principalement fonction de la taille des images. Cette méthode est donc applicable sur tous types de données hyperspectrales, indépendamment du nombre de bandes.

Conclusion générale

Cette thèse avait pour buts principaux la détection de galaxies à faible brillance de surface dans des images monobandes ainsi que la segmentation d'images astronomiques hyperspectrales. Nous avons, de plus, proposé une nouvelle méthode de segmentation floue des images multispectrales ainsi que deux nouvelles méthodes de visualisation d'images superspectrales (jusqu'à 50 bandes) sous la forme d'une composition colorée dans un espace de couleurs intuitif et simple d'utilisation. Le grand nombre de types d'images acquises (monobandes, multibandes, hyperspectrales...) conduit à des problématiques différentes pour chaque image. C'est la raison pour laquelle cette thèse a balayé un ensemble de problématiques concrètes liées aux besoins de la communauté astronomique.

Une méthode de segmentation multibande floue basée sur le modèle des champs de Markov a été présentée dans une première partie. La segmentation floue, contrairement à la segmentation dure, considère qu'un pixel peut appartenir à une ou deux classes dures avec un certain degré d'appartenance. Cette approche floue se prête particulièrement bien aux observations astronomiques dans lesquelles les frontières entre objets et fond ne sont pas clairement définies : les pixels présents à la périphérie des objets appartiendront donc à une classe floue puisqu'il est délicat de déterminer la classe réelle de ce pixel (*i.e.*, *fond* ou *objet*). Le modèle markovien flou se décompose en deux sous-modèles :

- un modèle spatial (modèle du champ des étiquettes) qui prend en compte le voisinage direct de chacun des pixels. Un pixel aura ainsi une forte probabilité d'appartenance à la classe 0 (*resp.* 1) si il est entouré de pixels de classe 0 (*resp.* 1). Ce modèle introduit une régularisation spatiale forte ;
- un modèle d'attache aux données (modèle de l'observation) modélisant le bruit (supposé gaussien dans notre cas) présent dans l'observation sous la forme d'un terme d'attache aux données.

Le modèle markovien nécessite alors l'estimation des paramètres de chacun de ces deux modèles. L'estimation des paramètres du bruit s'effectue avec les moments empiriques tandis que celles des paramètres du modèle spatial se font en utilisant le gradient stochastique de Younès. Cependant, l'estimation de ces paramètres est tributaire de la sensibilité du modèle spatial aux paramètres *a priori*. Nous proposons donc une méthode de segmentation semi-supervisée. La segmentation peut être rendue totalement non-supervisée en omettant le paramètre de régularisation des classes floues (clique d'ordre 1). Il serait intéressant d'étudier le gradient stochastique de Younès ainsi que l'expression analytique de son pas de convergence. L'estimation pourrait alors être rendue plus robuste et plus rapide en terme de temps de calcul (l'algorithme du gradient stochastique nécessitant la génération d'un champ *a priori* à chaque itération). Néanmoins, les résultats présentés justifient l'apport d'une approche floue dans la segmentation d'images multibandes astro-

nomiques.

La segmentation markovienne dure est directement utilisée dans la partie suivante qui a introduit une méthode de détection de galaxies à faible brillance de surface (galaxies LSB). Les galaxies LSB sont des objets dont la brillance centrale est inférieure à la limite isophotale (seuil de détection). Elles sont souvent noyées dans le bruit et dans la composante *fond* de l'image. Il n'est donc pas possible de les détecter en seuillant simplement l'image puisque le seuil élimine une partie du fond (et donc une partie des galaxies LSB). Nous avons donc proposé l'utilisation d'une approche markovienne qui, par une estimation fine des paramètres du bruit, fait ressortir les galaxies LSB dans une carte de segmentation. Puis, en utilisant la carte de segmentation comme masque, nous avons développé (en collaboration avec les astronomes), un ensemble d'étapes de sélections basées sur des critères morphologiques ainsi que sur la forme du profil radial de l'objet. Les critères utilisés correspondent à des hypothèses astronomiques. A l'issue de cette série d'élimination d'objets, nous avons présenté quelques résultats de détection. Les résultats obtenus comprennent un ensemble de caractéristiques astronomiques ainsi qu'une sortie au format VOTable pour affichage dans le logiciel Aladin. L'extension de cette méthode à des images multibandes est évoquée et pourrait permettre de raffiner la segmentation initiale en utilisant l'information portée par les deux bandes.

Une image multibande étant un ensemble d'images monobandes, son interprétation et sa visualisation restent difficiles à cause du grand nombre de plans. C'est la raison pour laquelle nous avons proposé, dans une troisième partie, deux méthodes de visualisation d'images multibandes dans un espace coloré TSL (Teinte Saturation Luminance) basée sur une carte de segmentation obtenue sur le quadarbre markovien. La première méthode propose d'utiliser les deux premiers axes d'une analyse factorielle discriminante afin de paramétrer les deux axes T et S de l'espace coloré. L'analyse factorielle discriminante (ou analyse de Fischer) projette les données dans un espace maximisant la variance inter-classes tout en minimisant la variance intra-classe. Cela correspond, dans la composition colorée, à la maximisation du contraste inter-classes et à la minimisation du contraste intra-classe. Une analyse en composantes principales est ensuite effectuée par classe et le pourcentage des valeurs propres de chacune des ACP locales est utilisée afin de paramétrer l'axe L. Lorsque le nombre de bandes de l'observation dépasse la dizaine, nous proposons de réduire l'observation afin d'obtenir une carte de segmentation puisque le classifieur markovien n'accepte qu'une dizaine de bandes en entrée. Cette méthode conduit à de bons résultats mais la composition résultante est difficilement interprétable du fait de l'utilisation de deux projections peu intuitives. Cependant, elle permet, dans un premier temps, de visualiser les comportements spectraux proches sur une seule image, mais ne permet pas de déduire des caractéristiques spectrales précises sur les zones de la composition. C'est la raison pour laquelle une deuxième méthode de visualisation a été introduite. Cette nouvelle méthode est basée sur des critères beaucoup plus familiers aux astronomes. Ainsi l'axe T est paramétré par un indice de couleur représentatif de l'émission de l'objet. Le canal S est paramétré par un indice de variabilité spectrale renseignant sur le caractère continu ou "piqué" du spectre. Enfin le canal L est le résultat de la projection des spectres, par classe, sur la première composante principale d'une ACP. La luminosité dépendra donc directement de l'écart du spectre par rapport à la moyenne de sa classe. Cette méthode n'est cependant pas applicable sur des données préalablement

réduites par ACP car cette projection ne conserve pas les caractéristiques spectrales du cube. Il serait donc ainsi envisageable de proposer une méthode de réduction conservant les caractéristiques des spectres du cube afin de permettre l'utilisation d'une segmentation markovienne par la suite. Cette deuxième méthode est beaucoup plus intuitive, familière aux astronomes et facilite l'interprétation et la prise en main des données. Ces deux méthodes ont été validées sur des images astronomiques ainsi que sur une image issue du domaine de la télédétection.

La méthode de visualisation a soulevé le problème de segmentation de grands cubes de données. En effet, la réduction fait perdre les caractéristiques spectrales de chacun des objets et la segmentation markovienne ne peut accepter plus de 10 bandes en entrée. Nous avons donc introduit, dans un dernier chapitre, une méthode de segmentation basée sur des critères spectraux. Nous avons proposé de projeter les spectres de l'observations sur une base de spectres préalablement définie. Une fois cette projection effectuée, nous utilisons l'algorithme des Mean-Shift afin de déterminer les modes de la distribution des poids de projection. Ces modes définissent alors une nouvelle base de projection et l'algorithme est itéré jusqu'à convergence de la base de spectres. Les images de poids de projection sont alors segmentées par quardarbre markovien (si $c < 10$) ou par algorithme des K-Moyennes (si $c > 10$). La segmentation markovienne va introduire une régularisation spatiale de la carte de segmentation. La méthode de projection utilisée est dépendante de l'intensité des spectres. Ainsi, il est possible de voir apparaître un grand nombres de classes de luminosité, les spectres étant différenciés par leur intensité et leur comportement spectral. Cependant, en astronomie, certains objets peuvent avoir les mêmes comportements spectraux mais à des intensités différentes. Afin de ne pas classifier différemment ces deux objets, nous avons introduit une mesure d'angle spectral invariante en intensité. La classification portera donc uniquement sur la forme des spectres. L'astronome peut utiliser l'une ou l'autre des méthodes de projection selon les besoins de son étude. L'utilisation de l'algorithme des Mean-Shift nécessite la définition d'un rayon h (nommée largeur de bande). Ce rayon est fixé empiriquement dans notre méthode mais peut être estimé par différents algorithmes nécessitant également l'introduction de nouveaux paramètres. Afin de proposer une segmentation totalement non supervisée à la communauté astronomique, il serait envisageable de déterminer une méthode d'estimation de h automatique. De plus, l'utilisation des Mean-Shift est très couteuse en temps de calcul. La recherche de voisins dans un espace de grande dimension fait l'objet de travaux et pourrait être étudiée afin de proposer un algorithme des Mean-Shift plus rapide en temps de calcul. Enfin, un gain de temps non négligeable pourrait être obtenu en parallélisant l'algorithme. Notre méthode de segmentation a été testée et validée sur un ensemble de données astronomiques simulées ainsi que sur une image issue du domaine de la télédétection. Elle peut être appliqué sur tout type de données hyperspectrales indépendamment du nombre de bandes.

Enfin il est important de souligner le travail de validation des méthodes par la communauté astronomique qui a permis, par le retour des experts, d'ajuster et d'améliorer nos méthodes. Cette interaction est primordiale dans le cadre du développement de méthodes applicatives et est bénéfique pour les deux communautés.

Publications de l'auteur

- F. Salzenstein, C. Collet, M. Petremand : “Fuzzy Markov Random Fields for multispectral images” - *Traitement du signal (TS)*, 21(1), Jan 2004
- M. Petremand, M. Louys, C. Collet : “Color display for multiwavelength astronomical images” - *Traitement du signal (TS)*, Numéro spécial, 21(6), Dec 2004
- M. Petremand, Ch Collet, F. Flitti, F. Bonnarel, B. Vollmer, W. van Driel : “Bayesian detection of low surface brightness galaxies” - *Statistical Challenge in Modern Astronomy : SCMA'06*, June 12-15, Penn State University, Pennsylvania, USA, 2006
- M. Petremand, C. Collet, M. Louys, F. Bonnarel : “Reduction and segmentation of hyperspectral data cubes” - *ADASS (Astronomical Data Analysis Software & Systems) conference*, 15-18 October 2006, Tucson, Arizona, USA
- M. Petremand, Ch Collet, M. Louys and F. Bonnarel : “Color Representation for Multiband Images thanks to Bayesian Classifier” - *Astronomical Data Analysis III* , 28 April - 1 May, 2004 Sant'Agata sui due Golfi (NA) Italy, April 2004
- A soumettre : M. Petremand, C. Collet, M. Louys : “Colored visualization of astronomical multiwavelength images” - *MNRAS (Monthly Notices of the Royal Astronomical Society)*
- A soumettre : M. Petremand, C. Collet, B. Vollmer : “Low surface brightness (LSB) galaxy detection” - *Astronomy & Astrophysics*

Bibliographie

- [1] Babich, G.A. ; Camps, O.I. Weighted parzen windows for pattern classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18, 1996.
- [2] E. Oja A. Hyvarinen, J. Karhunen. *Independent Component Analysis*. Wiley-Interscience, 2001.
- [3] A.Barron, J.Rissanen, B.Yu. The minimum description length principle in coding and modeling. *IEEE Trans. Information Theory*, 44, 1998.
- [4] E. Aptoula, S. Lefèvre, and C. Collet. Mathematical morphology applied to the segmentation and classification of galaxies in multispectral images. In *European Signal Processing Conference*, Florence, Italy, Sep 2006.
- [5] J. Ming B. Bhanu, L. Sungkee. Adaptive image segmentation using a genetic algorithm. *IEEE Transactions on Systems, Man and Cybernetics*, 25(12) :1543–1567, December 1995.
- [6] B. Georgescu and I. Shimshoni and P. Meer. Mean shift based clustering in high dimensions : A texture classification example. *9th International Conference on Computer Vision, Nice, France*, 2003.
- [7] M. Bartkowiak and M. Domanski. Efficient representation of chrominance for very low bitrate coding. In *Third european conference, Multimedia applications, services and techniques*, pages 415–424, Berlin, Germany, May 1998.
- [8] J.O. Berger. *Statistical Decision Theory and Bayesian Analysis*. Springer, 1993.
- [9] M. Berman, H. Kiiveri, R. Lagerstrom, A. Ernst, R. Dunne, and J. Huntington. Ice : An automated statistical approach to identifying endmembers. In *Proc. 2003 IEEE International Geoscience and Remote Sensing Symposium*, volume 1, pages 279–283, Toulouse, France, July 2003.
- [10] J. Bilmes. A gentle tutorial on the em algorithm and its application to parameter estimation for gaussian mixture and hidden markov models. Technical Report ICSI-TR-97-021, University of Berkeley, <http://ssli.ee.washington.edu/people/bilmes/mypapers/em.pdf>, 1997.
- [11] Bonnarel F., Fernique P., Bienayme O., Egret D., Genova F., Louys M., Ochsenbein F., Wenger M., Bartlett J.G. The aladin interactive sky atlas. a reference tool for identification of astronomical sources. *Astron. Astrophys., Suppl. Ser.*, 143 :33–40, April 2000.
- [12] A. Braquelaire and R. Strandh. A color model for rendering linear passive graphic 2d objects. Technical Report 1266-01, LaBRI, Université Bordeaux 1, 2001.

- [13] J.-Y. Chen. Image database management using similarity pyramids. *PhD, Purdue University, USA*, May 1999.
- [14] J. Y. Chen and P. Bouman. *Image Database Management Using Similarity Pyramids*. PhD thesis, Purdue University, May 1999.
- [15] C. Collet and F. Murtagh. Segmentation based on a hierarchical markov model. *Pattern Recognition*, 37(12) :2337–2347, December 2004.
- [16] N. Cristianini and J. Shawe-Taylor. *An introduction to support vector machines (and other kernel-based learning methods)*. Cambridge University Press, 2000.
- [17] Comaniciu D. and Meer P. Mean shift : a robust approach toward feature space analysis. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 24(5) :603–619, 2002.
- [18] P. Meer D. Comaniciu, V. Ramesh. The variable bandwidth mean-shift and data-driven scale selection. In *IEEE Int. Conf. Computer Vision (ICCV'01)*, volume 1, pages 438–445, Vancouver, Canada, 2001.
- [19] D. Comaniciu, P. Meer. Mean shift : a robust approach toward feature space analysis. *IEEE Transactions on pattern analysis and machine intelligence*, 24(5), May 2002.
- [20] H. Derin and H. Elliott. Modeling and segmentation of noisy and textured images using Gibbs random fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-9(1) :39–55, January 1987.
- [21] R. O. Duda, P. E. Hart, and D. G. Stork. *Pattern Classification*. John Wiley and Sons, 2001.
- [22] N. Merhav E. Levitan. A competitive neyman-pearson approach to universal hypothesis testing with applications. *IEEE Transactions on Information Theory*, 48 :2215–2229, August 2002.
- [23] F. Flitti. Techniques de réduction de données et analyse d'images multispectrales astronomiques par arbres de markov. *Thèse soutenue en déc. 2005, téléchargeable sur <http://lsiit-miv.u-strasbg.fr/lsiit/perso/collet>*, LSIIT - Laboratoire des Sciences de l'Image, de l'Informatique et de la Télédétection.
- [24] F. Flitti, C. Collet, B. Vollmer, F. Bonnarel. Data reduction for multiband segmentation : application to the virgo cluster galaxy NGC 4254. *EURASIP journal on Applied Signal Processing, special issue on Applications of Signal Processing in Astrophysics and Cosmology*, 15 :2546–2558, 2005.
- [25] F. Flitti and C. Collet. ACP et ACI pour la réduction de données en imagerie astronomique multispectrale. *19ème colloque sur le traitement du signal et des images, GRETI*, CD-ROM, Paris, France, Septembre 2003.
- [26] Francis R. Bach, Michael I. Jordan. Learning spectral clustering. *Advances in Neural Information Processing Systems*, 2004.
- [27] S. Grossberg G. carpenter. An adaptive resonance algorithm for rapid category learning and recognition. *Neural Networks*, (4) :493–504, 1991.
- [28] P.D. Gader. Segmentation tools in mathematical morphology. *Image Algebra and Morphological Image Processing*, 1350 :70–84, November 1990.
- [29] A. Gelman. *Bayesian data analysis second edition*. Chapman and Hall, 2003.

- [30] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-6(6) :721–741, November 1984.
- [31] T. Gevers and A.W.M. Smeulders. Color based object recognition. *Pattern Recognition*, 32 :453–464, March 1999.
- [32] D.E. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, 1989.
- [33] Kee-Chunh Ho. Iterated conditional modes for inverse halftoning. *Proceedings of the 2004 Symposium on Circuits and Systems (ISCAS)*, (3) :901–904, May 2004.
- [34] G.F. Hughes. On the mean accuracy of statistical pattern recognizers. *IEEE Trans. Information Theory*, 14(1) :55–63, 1968.
- [35] A. Hyvärinen, J. Karhunen, and E. Oja. *Independent Component Analysis*. John Wiley and Sons, 2001.
- [36] J-M. Laferté, P. Pérez, F. Heitz. Discrete markov image modeling and inference on the quad-tree. *IEEE Trans. Image Process.*, 9(3) :390–404, 2000.
- [37] M. Jamzad, B.S. Sadjad, V.S. Mirrokni, M. Lazemi, H. Chitsaz, A. Heydarnoori, M.T. Hajiaghahi, and A. Chiniforooshan. A fast vision system for middle size robots in robocup. *Lecture Notes in Computer Science*, 2377, 2001.
- [38] L. Jimenez and D. Landgrebe. High dimensional feature reduction via projection pursuit. *School of Electrical and Computer Engineering, Purdue University, West Lafayette in 47907-1285*, April 1995.
- [39] J.L. Schafer. *Analysis of incomplete multivariate data*. Chapman and Hall/CRC, 1997.
- [40] J.N. Provost, C. Collet, P. Rostaing, P. Pérez and P. Bouthemy. Hierarchical Markovian segmentation of multispectral images for the reconstruction of water depth maps. *Computer Vision and Image Understanding*, 93(2) :155–174, February 2004.
- [41] T. Kohonen. Clustering, taxonomy and topological maps of patterns. *IEEE Sixth international conference on pattern recognition*, (8) :114–122, 1982.
- [42] M. Luetgen. Image processing with multiscale stochastic models. *Phd thesis*, MIT Laboratory of Information and Decision Systems, 1993.
- [43] A. Mojsilovic. A method for color naming and description of color composition in images. *Proc. Int. Conf. on Image Processing*, Sept. 2002.
- [44] N. Acito, G. Corsini, G., M. Diani. An unsupervised algorithm for the selection of endmembers in hyperspectral images. *Geoscience and Remote Sensing Symposium, 2002. IGARSS '02. 2002 IEEE International*, 3, June 2002.
- [45] M.R. Gupta N.P. Jacobson. Design goals and solutions for display of hyperspectral images. *IEEE International Conference on Image Processing, 2005*, 2, 2005.
- [46] P. Bajorski, E.J. Ientilucci, J.R. Scott. Comparison of basis-vector selection methods for target and background subspaces as applied to subpixel target detection. Technical Report 2004-3, Center for quality and applied statistics, Rochester institute of technology, NY, USA, 2004.

- [47] A. Peng and W. Pieczynski. Adaptive mixture estimation and unsupervised local bayesian image segmentation. *Graphical Models and Image Processing*, 57(5) :389–399, 1995.
- [48] G. Perrin, X. Descombes, and J. Zerubia. Adaptive simulated annealing for energy minimization problem in a marked point process application. In *Proc. Energy Minimization Methods in Computer Vision and Pattern Recognition (EMMCVPR)*, St Augustine, Florida, USA, novembre 2005.
- [49] P.Grünwald. *A Tutorial introduction to the minimum description length principle*. MIT Press, 2005.
- [50] Eric Pichon, Marc Niethammer, and Guillermo Sapiro. Color histogram equalization through mesh deformation. In *IEEE International Conference on Image Processing, Barcelone*, volume 2, pages 117–120, 2003.
- [51] W. Pieczynski. Modèles de markov en traitements d’images. *Traitement du Signal*, 20(3) :255–278, 2003.
- [52] J.-N Provost. *Classification bathymétrique en imagerie multispectrale SPOT*. PhD thesis, Université de Bretagne Occidentale, Ecole navale - Laboratoire GTS, Brest, France, téléchargeable sur <http://lsiit-miv.u-strasbg.fr/lsiit/perso/collet>, 2001.
- [53] D. Monnier Ragaigne, W. van Driel, S.E. Schneider, T.H. Jarrett, and C. Balkowski. Chemical and spectrophotometric evolution of low surface brightness galaxies. *MNRAS*, 343, 2003.
- [54] Robert C. Kennicutt, JR. A spectrophotometric atlas of galaxies. *Astronomy and Astrophysics*, 79, 1992.
- [55] F. Rosenblatt. The perceptron : A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6) :686–408, November 1958.
- [56] N. Prantzou W. van Driel C. Balkowski K. O’Neil S. Boissier, D. Monnier Ragaigne. A search for low surface brightness galaxies in the near-infrared i. selection of the sample. *Astron. Astrophys.*, 405 :99–110, 2003.
- [57] S. Hatton, J. Devriendt, S. Ninin, F.R. Bouchet, B. Guiderdoni, D. Vibert. Galics - i. a hybrid n-body/semi-analytic model of hierarchical galaxy formatio. *Astronomy and Astrophysics*, 343, 2003.
- [58] S. Roweis, L. Saul. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 290(5500) :2323 – 2326, December 2000.
- [59] S. Sabatini, J. Davies, R. Scaramella, R. Smith, M. Baes, S. M. Linder, S. Roberts, and V. Testa. The dwarf low surface brightness galaxy population of the virgo cluster i. the faint-end-slope of the luminosity function. *Mon.Not.Roy.Astron.Soc.*, 341 :981, 2003.
- [60] F. Salzenstein. *Modèles markoviens flous et segmentation statistique non supervisée d’images*. Thèse de doctorat (PhD thesis), Université Rennes 1 - Institut National des Télécommunications d’Evry, décembre 1996.
- [61] F. Salzenstein and C. Collet. Fuzzy markov random fields versus chains for multispectral image segmentation. *A paraître : IEEE Trans. on PAMI*, Jun 2006.
- [62] F. Salzenstein, C. Collet, and M. Petremand. Fuzzy markov random fields for multispectral images. *Traitement du signal*, 21(1), Jan 2004.

- [63] F. Salzenstein and W. Pieczynski. Sur le choix de la méthode de segmentation statistique d'images. *Traitement du signal*, 15(2) :119–127, 1998.
- [64] P. Scheunders. Local mapping for multispectral image visualization. *Image and Vision Computing*, 19 :971–978, 2001.
- [65] GALICS (Galaxies In Cosmological Simulations). <http://galics.cosmologie.fr/>.
- [66] S. Mitra S.K. Pal. Multilayer perceptron, fuzzy sets, and classification. *IEEE Transactions on Neural Networks*, 3(5) :683–697, September 1992.
- [67] S.laugier, D. Burgarella, V. Buat. Spectro-morphology of galaxies : a multi-wavelength (uv-r) evolutionary method. *Astronomy and Astrophysics*, Octobre 2004.
- [68] G.L. Smith. Principal component analysis : an introduction. *Analytical Proceedings*, 28 :150–151, May 1991.
- [69] P. Soille. *Morphological image analysis*. Springer, 2004.
- [70] J.L. Starck and F. Murtagh. Astronomical image and signal processing. *IEEE Signal Processing Magazine*, pages 1–10, March 2001.
- [71] P.E. Trahanias and A.N. Venetsanopoulos. Color image enhancement through 3-d histogram equalization. In *Proceedings of the 15th LAPR international conference on pattern recognition*, 1992.
- [72] D. Travis. *Effective color displays, theory and practice*. Academic press, 1991.
- [73] U. von Luxburg, O. Bousquet, M. Belkin. Limits of spectral clustering. *Advances in Neural Information Processing Systems*, 2004.
- [74] M. Volle. *Analyse des données*. Economica, 1985.
- [75] Weisberg, A. Najarian, M. Borowski, B. Lisowski, J. Miller, B. Spectral angle automatic cluster routine (saalt) : an unsupervised multispectral clustering algorithm. *Aerospace Conference. Proceedings. IEEE*, 4, 1999.
- [76] G. Wyszecki and W.S. Stiles. *Color science : concepts and methods, quantitative data and formulae : second edition*. Wiley, 1982.
- [77] Y. Bengio, P. Vincent, J.F. Paiement, O. Delalleau, M. Ouimet, N. Le Roux. Spectral clustering and kernel pca are learning eigenfunctions. Technical Report 2004-3, Département d'informatique et recherche opérationnelle, centre de recherches mathématiques, Université de Montréal, Canada, 2004.
- [78] Y. Linde, A. Buzo, R. Gray. An algorithm for vector quantizer design. *IEEE Transactions on Communications*, 28(1) :84 – 95, January 1980.
- [79] L. Younes. Parametric inference for imperfectly observed Gibbsian fields. *Springer-Verlag Probability Theory and Related Fields* 82, pages 625–645, 1989.

Résumé :

Les progrès technologiques de l'instrumentation astronomique soulèvent des problématiques variées. L'imagerie monobande permet, grâce aux capteurs de résolution et de sensibilité croissante, de découvrir des objets autrefois inobservables. En particulier, le développement des capteurs multispectraux permet l'acquisition de masses de données porteuses d'une information très riche. Néanmoins, l'interprétation et le traitement de tels volumes de données restent délicats pour la communauté astronomique. Dans le cadre de cette thèse nous proposons un ensemble de méthodes facilitant le processus d'interprétation réalisé par l'astronome. Nous introduisons une nouvelle méthode de segmentation floue par champs de Markov permettant de prendre en compte les spécificités des observations astronomiques : frontières des objets non définies et objets diffus. Un pixel flou de la carte de segmentation appartient ainsi à une ou deux classes dures en fonction d'un certain degré d'appartenance. Nous proposons également une méthode de détection de galaxies à faible brillance de surface (galaxies LSB) basée sur l'utilisation d'une segmentation markovienne par quadarbre. Cette segmentation permet de dégager les galaxies LSB du fond de ciel grâce à une estimation fine de la statistique du bruit présent dans l'observation. Un ensemble d'étapes de sélection est ensuite mis en oeuvre afin de caractériser la galaxie. Nous proposons deux méthodes de visualisation d'images multispectrales permettant de synthétiser l'information portée par toutes les bandes dans une composition colorée réalisée dans l'espace TSL (Teinte Saturation Luminance). Enfin, nous étudions une nouvelle méthode de segmentation de cubes de données hyperspectraux basée sur une approche de discrimination spectrale puis sur une régularisation spatiale de la carte de segmentation par une approche markovienne par quadarbre. Ces méthodes sont validées sur des images astronomiques et ont fait l'objet d'une interaction particulièrement riche entre communauté STIC et communauté astronomique. De plus, deux méthodes sont validées sur des images issues du domaine de la télédétection pour lesquelles certaines problématiques restent communes.

Mots-clés : Imagerie hyperspectrale, modèles markoviens flous, segmentation, réduction de dimensionnalité, visualisation, détection de galaxies, astronomie.

Abstract :

Technological progress in astronomical instrumentation raise various issues. Thanks to the growing sensor sensitivity, monospectral imagery make it possible to discover objects which were previously impossible to detect. The development of multispectral sensors yields extremely valuable data. Nevertheless interpretation and processing of such images remain tricky for the astronomical community. Within the framework of this thesis we propose a set of methods that make the interpretation process easier for the astronomer. We introduce a new fuzzy segmentation method based on Markov fields allowing to take into account the specificities of astronomical objects : fuzzy boundaries and diffuse objects. A fuzzy pixel of the segmentation map thus belongs to one or two hard classes depending on a certain membership level. We also propose a new method for the detection of Low Surface Brightness (LSB) galaxy based on a quadtree Markovian segmentation. This segmentation allows to highlight the LSB within the observation background through an accurate estimation of the noise statistics contained in the acquisition. A set of selection steps is then carried out to determine if the detected object is a LSB. We then introduce two multispectral images visualization methods allowing to synthetize the information contained by all the observation bands in a colored composition in the HSV color space (Hue Saturation Value). Finally we propose a new segmentation method of hyperspectral data cubes based on a spectral discrimination and on a spatial regularization of the segmentation map obtained thanks to a quadtree segmentation. These methods are validated on astronomical images and led to a fruitful cooperation between computer vision community and astronomical community. Furthermore two methods have been validated on remote sensing observation for which some specific issues remain common.

Key words : Hyperspectral imagery, fuzzy Markovian models, segmentation, dimensionality reduction, visualization, galaxy detection, astronomy.