

UNIVERSITE SAAD DAHLAD BLIDA

Faculté de Technologie
Département d'Électronique

MEMOIRE DE MAGISTER
En Electronique

Spécialité : Signaux et systèmes

DÉCOMPOSITION DATA DRIVEN POUR
L'ESTIMATION DES PROPORTIONS D'OCCUPATION
DU SOL

Par

BERKANE Samain

Devant le jury composé de

Mr Z.BENSELAMA	Maitre de conférences A, USD de BLIDA	Président
Mme M.GUERTI	Professeur, ENP ALGER	Examineur
Mr S.ZAIR	Maitre Assistant A, USD de BLIDA	Examineur
Mlle N.BENBLIDIA	Maitre de Conférences A, USD de BLIDA	Promotrice
Mlle F.REGUIEG	Maitre Assistante A, USD de BLIDA	Co-promotrice

Remerciement

Tout puissant et miséricordieux, qui nous a donné la force et la patience
d'accomplir ce Modeste travail.

En second lieu, nous tenons à remercier notre promotrice Mlle N. BENBLIDIA, son
précieux conseil et son aide durant toute la période du travail.

Mes remerciements s'adressent également à notre Co-promotrice Mlle F.REGUIEG
pour m'avoir encadré, aidé et encouragé pour bien mener ce travail.

Nos vifs remerciements vont également aux membres du jury pour l'intérêt qu'ils ont porté
à notre travail en acceptant de l'examiner, et de l'enrichir par leurs propositions.

Enfin, nous tenons également à remercier toutes les personnes qui ont participé de près ou
de loin à la réalisation de ce travail.

RESUME

L'imagerie satellitaire est très largement employée en télédétection pour diverses applications, dans le domaine civil comme dans le domaine militaire. Une image satellitaire est le résultat de l'acquisition d'une seule scène observée dans plusieurs longueurs d'ondes. Par conséquent, chacun des pixels constituant cette image est représenté par un vecteur de mesures appelé spectre. On admet que pour chaque pixel on observe un mélange d'éléments purs. Ces hétérogénéités spatiales et spectrales limitent la fiabilité des méthodes conventionnelles de classification de l'imagerie satellitaire.

Plusieurs techniques ont été développées pour l'analyse d'image satellitaire en prenant en considération le problème de mélange, on peut les diviser en deux catégories, les techniques supervisées et non supervisées.

Ce mémoire a pour but de développer un algorithme de démixage spectral qui est basé sur les méthodes de mesure spectral et à l'analyse en composantes indépendantes en essayons d'améliorer les résultats des méthodes primaires.

Mots clés : Image de télédétection, classification, pixel mixte, démixage spectral, mesure spectral, analyse en composante principale, analyse en composante indépendantes.

ملخص

تستخدم صور الاستشعار عن بعد الملتقطة عن طريق الأقمار الصناعية في مختلف التطبيقات المدنية والعسكرية. صور الاستشعار عن بعد هي نتيجة لعملية الاستحواذ على مشهد واحد لوحظت في العديد من الأطوال الموجية، وبالتالي فإن كل بكسل من الصورة يمثل بشعاع من القياسات يدعى الطيف. ويمكن اعتبار أن كل بكسل ملاحظ هو عبارة عن خليط من المواد النقية. هذا عدم التجانس الفضائي و الطيفي يحد من مصداقية الطرق التقليدية لتصنيف صور الاستشعار عن بعد. هناك عدة طرق تم تطويرها من أجل تحليل صور الاستشعار عن بعد مع الأخذ بعين الاعتبار مشكل الخليط الغير المتجانس، حيث يمكن تقسيم هذه الطرق إلى فئتين، طرق خاضعة للإشراف وغير خاضعة للإشراف. تهدف هذه الرسالة إلى تطوير خوارزمية للفصل الطيفي التي تعتمد على طرق القياس الطيفي و التحليل إلى عوامل مستقلة و محاولة تحسين نتائج الطرق الابتدائية

كلمات البحث: صورة الاستشعار عن بعد، التصنيف، بكسل المختلط، التحليل الطيفي، قياس الطيفي، تحليل إلى المركبات الرئيسية، تحليل إلى المركبات المستقلة.

ABSTRACT

Satellite imagery is widely used in remote sensing for various applications in civil as in military. A satellite image is the result of the acquisition of a single scene observed in several wavelengths. Therefore, each of pixels constituting the image is represented by a vector of measures called the spectrum. It is assumed that for each pixel there is a mixture of pure elements. These spectral and spatial heterogeneities limit the reliability of conventional methods of classification of satellite imagery. Several techniques have been developed for the analysis of satellite images by considering the problem of mixture, little divided on two categories, technical supervised and unsupervised. This thesis aims to develop a spectral unmixing algorithm that is based on measurement methods and spectral independent component analysis in trying to improve the results of the primary methods.

Keywords: Image of remote sensing classification, mixed pixel, spectral unmixing, spectral measurement, principal component analysis, independent component analysis.

TABLE DES MATIERES

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX.....	3
INTRODUCTION	7
1. PRINCIPES DE LA TÉLÉDÉTECTION	9
1.1 INTRODUCTION.....	9
1.2 DEFINITION.....	9
1.3 HISTORIQUE.....	10
1.4 PRINCIPE DE LA TELEDETECTION	12
1.5 CONCLUSION	23
2. ACQUISITION, TRAITEMENT ET APPLICATION DES IMAGES DE TELEDETECTION.....	24
2.1 INTRODUCTION.....	24
2.2 LES SATELLITES DE LA TELEDETECTION.....	24
2.3 LES IMAGES SATELLITAIRES	30
2.4 TRAITEMENT ET ANALYSE DES IMAGES DE TELEDETECTION.....	32
2.5 LES APPLICATIONS DE L'IMAGERIE SATELLITAIRE	37
2.6 CARTE D'OCCUPATION ET D'UTILISATION DU SOL.....	39
2.7 CONCLUSION.....	41
3. TECHNIQUES DE DÉMIXAGE SPECTRAL	42
3.1 INTRODUCTION	42
3.2 PROBLEME DE LA MIXTURE SPECTRALE.....	42
3.3 MODELISATION DE L'IMAGE SATELLITAIRE.....	44
3.4 LES TECHNIQUES DE DEMIXAGE SPECTRAL.....	47
3.5 CONCLUSION	65
4. MISE EN ŒUVRE ET APPLICATION DU SYSTEME DE DEMIXAGE	67
4.1 INTRODUCTION	67

4.2 MATERIELS ET DONNEES.....	70
4.3 ANALYSE EN COMPOSANTES PRINCIPALES.....	71
4.4 APPLICATIONS DES TECHNIQUES DE MISE EN CORRESPONDANCE	75
4.5 LA CLASSIFICATION PAR ANALYSE EN COMPOSANTES INDEPENDANTES ET VCA	92
4.6 ÉVALUATION STATISTIQUE DE LA CLASSIFICATION	98
4.7 AMELIORATION DES PERFORMANCES DU SYSTEME	102
4. 8 CONCLUSION	109
CONCLUSION GENERALE	110
RECOMMANDATIONS.....	112
REFERENCES.....	114

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

Figure 1.1 : Onde électromagnétique	14
Figure 1.2 : Le spectre électromagnétique et l'énergie correspondante	15
Figure 1.3 : Interactions du rayonnement solaire avec l'atmosphère	16
Figure 1.4 : L'interaction rayonnement matière	18
Figure 1.5 : Signatures spectrales des surfaces naturelles	20
Figure 1.6 : Les éléments principaux de la télédétection	21
Figure 1.7 : Etapes de la télédétection	22
Figure 2.1 : Les orbites des satellites	26
Figure 2.2 : La fauchée d'un satellite	27
Figure 2.3 : Les 4 types de la résolution	27
Figure 2.4 : Les satellites d'observation de la terre	30
Figure 2.5 : Image satellitaire	32
Figure 2.6 : Création d'image en fausses couleurs	34
Figure 2.7 : Les trois types d'étalement de contraste	36
Figure 2.8 : La classification multispectrale	37
Figure 2.9 : Classification supervisée	37
Figure 2.10 : Classification non supervisée	43
Figure 3.1 : Pixel pure et pixel mixte en imagerie satellitaire	44
Figure 3.2 : Modèles de mélange	44
Figure 3.3 : Modélisation de mélange spectral	44
Figure 3.4 : Représentation en deux bandes des observations non bruitées	47
Figure 3.5 : La projection de similarité	48
Figure 3.6 : Angle spectral entre le spectre de référence et le spectre image	49
Figure 3.7 : La similarité spectrale par la distance	51
Figure 3.8 : Illustration du problème de la malédiction de dimension	53
Figure 3.9 : La rotation des composants dans un espace	55

Figure.3.10 : Séparation aveugle des sources	58
Figure.3.11 : Schéma général	59
Figure.3.12: Schéma global	60
Figure 4.1 Organigramme global du système développé	68
Figure 4.2: Synoptique du système développé	69
Figure.4.3 : Image LANDSAT TM BIGORN BASIN .USA	70
Figure.4.4 :Image LANDSAT TM Canon City, Colorado.USA	70
Figure.4.5 : La fenêtre principale et modules y afférents	71
Figure .4.6 : Le nuage des points	72
Figure.4.7: Les composantes principales de l' image BIGORN BASIN	74
Figure.4.8 : L'organigramme des méthodes de mise en correspondance spectrale	75
Figure.4.9 : résultats obtenus par PPI	76
Figure.4.10 : Résultats obtenus par N-FINDER	77
Figure.4.11 : Résultats obtenus par ATGP	78
Figure 4.12 : Résultats obtenus par le polygone optimal	79
Figure 4.13 : Résultats obtenus par la VCA	80
Figure 4.14 : Résultats obtenus par l'ACI	80
Figure.4.15 : L' image de similarité obtenue par SAM	81
Figure.4.16 : L' image de similarité obtenue par SDS	82
Figure.4.17 : L' image de similarité obtenue par SVS	82
Figure.4.18 : Image de similarité obtenue par SVS	83
Figure.4.19 : Les résultats de biais	85
Figure.4.20 Résultats de classification par SAS BIGORN BASIN	86
Figure.4.21 Résultats de classification par SAS Canon City	87
Figure.4.22 Résultats de classification par SDS BIGORN BASIN	87
Figure.4.23 : Résultats de classification par SDS Canon City	88
Figure.4.24 : Résultats de classification par SCS BIGORN BASIN	88
Figure.4.25 : Résultats de classification par SCS Canon City	89
Figure.4.26 : Résultats de classification par SVS BIGORN BASIN	89
Figure.4.27 : Résultats de classification par SVS Canon City	90
Figure.4.28 : Résultats de classification par la fusion des techniques SAM, SCS et SVS	91

Figure.4.29 : Résultats de classification par la fusion des techniques SDS, SCS et SVS	91
Figure.4.30 : Résultats de classification par la fusion des techniques SAM, SCS et SDS	92
Figure.4.31 : Résultats de classification par la fusion des techniques SAM, SCS et SVS	92
Figure 4.32 : L'organigramme des méthodes non supervisée	92
Figure.4.33: Les composantes indépendantes Canon City, Colorado	93
Figure.4.34 : Résultats de classification par ACI BIGORN BASIN	94
Figure.4.35 : Résultats de classification par ACI Canon City	95
Figure.4.36 : Les images de fraction d'abondance obtenues par VCA	96
Figure.4.37 : Résultats de classification par VCA BIGORN BASIN	97
Figure.4.38 : Résultats de classification par VCA Canon City	97
Figure 4.39 : Organigramme de la coopération des méthodes	103
Figure 4.40 : Résultats de classification par la méthode hybride ACI - SAM	104
Figure 4.41 : Les résultats de classification par la méthode hybride ACI - SCS	105
Figure.4.42 : Résultats de classification par la méthode hybrid VCA - SAM	106
Figure.4.43 : Résultats de classification par la méthode hybrid VCA suivi par SCS	107
Tableau 4.1 : La corrélation entre différents canaux de l'image	72
Tableau 4.2 : Entropie des images	73
Tableau 4.3 : La corrélation entre les composantes principales	73
Tableau 4.4 : Résultats de l'ACP	73
Tableau 4.5 : Les pixels attribués par la technique SAM	99
Tableau 4.6 : Les paramètres de précision pour les mesures de similarité Canon City	100
Tableau 4.7 : Les paramètres de précision pour les mesures de similarité BIGORN BASIN	100
Tableau 4.8 : Les paramètres de précision pour la technique de fusion Canon City	101

Tableau 4.9 : Les paramètres de précision pour la technique de fusion BIGORN BASIN	100
Tableau 4.10 : Les paramètres de précision pour ACI et VCA Canon City	101
Tableau 4.11 : Les paramètres de précision pour ACI et VCA BIGORN BASIN	102
Tableau 4.12 : Les paramètres de précision pour les algorithmes hybrides ACI-SAM et ACI-SCS	108
Tableau 4.13 : Les paramètres de précision pour les pour les algorithmes hybrides VCA-SAM et VCA-SCS	108

INTRODUCTION

La télédétection spatiale permet d'acquérir une quantité importante d'informations sur les surfaces à différentes échelles spatiales et temporelles. Leur utilisation dans les domaines biophysique ou atmosphérique a prouvé son efficacité, et les satellites construits sont de plus en plus performants pour apporter des informations fines au service des applications visées.

Compte tenu des nombreux avantages offerts par l'imagerie satellitaire, le développement d'outils de traitement d'images et de modèles physiques surface-atmosphère a connu un essor marqué dans des domaines très divers durant ces dernières décennies.

En revanche l'application de la télédétection, à la cartographie de l'occupation du sol est l'un des grands enjeux actuels. L'occupation du sol peut être succinctement définie comme la couverture physique de la surface des terres émergées [1]. L'occupation du sol est sans cesse modifiée par différents processus naturels et anthropiques. L'étude du sol est alors utile pour la connaissance scientifique des dynamiques urbaines, sylvicultrices ou agronomiques. Les différents constituants du sol sont alors cartographiés en zones artificialisées, zones agricoles, zones forestières...

Le mélange des pixels est l'un des problèmes délicats de l'analyse des images de télédétection. On admet que pour chaque pixel on observe un mélange d'éléments purs. Il faut donc identifier ces éléments purs et en déterminer les proportions. Ces hétérogénéités spatiales et spectrales limitent la fiabilité des méthodes conventionnelles de classification de l'imagerie satellitaire. En effet, une classification classique étiquette un pixel, sans tenir compte du fait que celui-ci résulte du mélange de plusieurs types d'occupation du sol dans certaines proportions ; cela conduit à un résultat qui n'est pas fiable.

L'objectif de ce travail a pour but de mettre en place une méthode de démixage spectral appliquée à l'observation de surfaces hétérogènes par un capteur multispectral, pour avoir une carte d'occupation du sol plus fiable.

Pour la réalisation de ce travail, nous avons structuré le mémoire en quatre chapitres distincts:

Chapitre 1: ce chapitre présente le principe général et le fonctionnement de la télédétection.

Chapitre 2: ce chapitre est consacré à l'imagerie satellitaire ; quelques traitements appliqués sur ces images y sont présentés.

Chapitre 3: ce chapitre aborde le problème de mélange spectral ; les techniques de démixage spectral qui se basent sur le mélange linéaire sont ensuite décrites.

Chapitre 4 : ce chapitre présente l'implémentation des techniques citées dans le chapitre 3. Les expérimentations menées ont été réalisées en considérant des images Landsat TM. Ces tests ont été effectués en considérant les techniques séparément ou en les combinant dans un processus hybride

CHAPITRE 1 PRINCIPES DE LA TÉLÉDÉTECTION

1.1 Introduction

Ce chapitre présente le principe de la télédétection. Nous organisons ce chapitre comme suit : la section 1.2 donne les définitions de la télédétection ; dans la section 1.3, nous décrivons les différentes étapes de l'évolution de la télédétection. Le principe physique de la télédétection ainsi que les différentes notions et termes utilisés seront décrits dans la section 1.4.

1.2 Définitions

Le mot télédétection (en anglais <<remote sensing>>) désigne l'ensemble des techniques qui permettent d'étudier à distance des objets ou des phénomènes. Le néologisme << remote sensing>> a fait son apparition aux ETAS UNIS dans les années soixante, lorsque des capteurs nouveaux viennent compléter la traditionnelle photographique aérienne. Le terme de télédétection a été introduit officiellement dans la langue française en 1973 ; plusieurs définitions officielles ont été attribuées dont :

*Définition 1

La télédétection est la technique qui par l'acquisition d'images, permet d'obtenir de l'information sur la surface de la terre sans contact avec celle-ci. La télédétection englobe tous les processeurs qui consistent à capter et à enregistrer un rayonnement électromagnétique émis ou réfléchi à traiter et à analyser l'information pour ensuite mettre en application cette information [2].

* Définition 2

La télédétection est l'ensemble des connaissances et techniques utilisées pour déterminer des caractéristiques physiques et biologiques d'objets par des mesures effectuées à distance, sans contact matériel avec ceux-ci (journal officiel du 11 décembre 1980) [3].

* Définition 3

La télédétection est une technique basée sur les mesures physiques du rayonnement réfléchi, émis ou rétrodiffusé ou émis par la surface de la terre. La télédétection par satellite permet des observations régulières, répétitives, fidèles de la quasi-totalité de la planète, à divers pas d'espace et de temps, dans plusieurs domaines de longueur d'onde [4].

* Définition 4

La télédétection se définit comme l'ensemble des sciences et techniques d'identification, et de classification des objets et des matériaux, à partir de leur rayonnement électromagnétique réfléchi. La physique de la télédétection précise que chaque matériau présente une réflectivité spectrale. Elle est considérée comme la source à partir de laquelle les caractéristiques chimiques et physiques d'un matériau peuvent être retrouvées [5].

1.3 Historique

L'histoire des techniques de la télédétection peut être découpée en cinq grandes époques [6] :

1 - de 1856, date à laquelle, pour la première fois, un appareil photographique a été installé de façon fixe à bord d'un ballon, à la première guerre mondiale. C'est l'époque des pionniers, pendant laquelle sont explorées les possibilités de la photographie aérienne verticale pour la cartographie ; les lois fondamentales de la stéréoscopie et de la photogrammétrie sont découvertes à la fin du XIXe siècle.

2 - de la première guerre mondiale à la fin des années 50, la photographie aérienne devient un outil opérationnel pour la cartographie, la recherche pétrolière, la surveillance de la végétation. On assiste à un progrès continu de l'aviation, des appareils photographiques et des émulsions (couleur, infrarouge noir et blanc, infrarouge fausse couleur). Les méthodes de la photo-interprétation sont précisées et codifiées.

3 - la période qui commence en 1957 et s'achève en 1972 marque les débuts de l'exploration de l'espace et prépare l'avènement de la télédétection actuelle. Le lancement des premiers satellites, puis de vaisseaux spatiaux habités à bord desquels sont embarqués des caméras, révèle l'intérêt de la télédétection depuis l'espace. Parallèlement, les radiomètres-imageurs sont mis au point et perfectionnés, de même que les premiers radars embarqués à bord d'avions. La première application opérationnelle de la télédétection spatiale apparaît dans les années 60 avec les satellites météorologiques de la série ESSA.

4 - le lancement en 1972 du satellite ERTS (rebaptisé ensuite Landsat 1), premier satellite de télédétection des ressources terrestres, ouvre l'époque de la télédétection moderne. Le développement constant des capteurs et des méthodes de traitement des données numériques ouvre de plus en plus le champ des applications de la télédétection et en fait un instrument indispensable de gestion de la planète, et, de plus en plus, un outil économique.

5 - depuis les années 70, on assiste à un développement continu de la télédétection, marqué notamment par :

- l'augmentation de la résolution spatiale des capteurs, déjà évoquée.
- la diversification des capteurs qui utilisent des domaines de plus en plus variés et spécialisés du spectre électromagnétique. Dans les années 90, on assiste ainsi à la multiplication des satellites équipés de capteurs actifs, radars en particulier. Dans le domaine du rayonnement visible et infrarouge, les capteurs à très haute résolution spectrale sont aujourd'hui d'utilisation courante dans leur version aéroportée et font leur apparition à bord de satellites.
- la diffusion des données sur une base commerciale, envisagée dès le lancement du programme SPOT en 1986, se traduit aujourd'hui par le lancement de satellites de télédétection par des sociétés privées. Les données de télédétection deviennent l'objet d'un marché concurrentiel.

La diffusion accélérée et l'augmentation de la puissance des ordinateurs contribuent de façon continue à promouvoir de nouvelles méthodes d'utilisation des données toujours plus abondantes que fournit la télédétection spatiale. Les données des

satellites météorologiques et océanographiques sont aujourd'hui un auxiliaire indispensable de la prévision numérique du temps et du climat et font l'objet d'une assimilation directe par les modèles numériques. Les images de télédétection destinées à l'observation fine de la surface terrestre, y compris les photographies aériennes traditionnelles, sont, sous forme numérique, intégrées aux Systèmes d'Information Géographique.

1.4 Principe de la télédétection

La télédétection utilise les propriétés du rayonnement électromagnétique pour analyser à distance la surface du sol, de l'océan ou l'atmosphère. Une bonne connaissance de la physique élémentaire du rayonnement est indispensable à l'interprétation des résultats de la télédétection.

1.4.1 Rayonnement électromagnétique et spectre

Le rayonnement électromagnétique est une forme de propagation de l'énergie dans la nature, dont la forme qui nous est la plus familière est la lumière visible telle que la perçoit l'œil humain. Historiquement, la physique spécialisée dans l'étude du rayonnement (optique) est née de l'étude de la propagation de la lumière et de ses interactions avec les matériaux (optique géométrique). Le rayonnement a été ensuite reconnu par les physiciens comme un phénomène ondulatoire, en relation avec l'électricité et le magnétisme (optique électromagnétique), cette perspective a permis d'étendre considérablement le champ des connaissances sur le spectre du rayonnement électromagnétique, bien au-delà de la lumière visible. Enfin, la physique moderne a montré que le rayonnement électromagnétique pouvait également être considéré comme un déplacement de particules élémentaires représentant une quantité d'énergie (optique énergétique et quantique).

1.4.1.1 Les ondes électromagnétiques

Une onde électromagnétique correspond à la vibration simultanée dans l'espace d'un champ électrique et d'un champ magnétique. Une onde électromagnétique est une onde progressive et transversale ; le sens de la variation des champs est perpendiculaire à la direction de propagation. Elle se caractérise par :

- La longueur d'onde : elle équivaut à la longueur d'un cycle d'une onde, ce qui correspond à la distance entre deux crêtes successives d'une onde. La longueur d'onde est représentée habituellement par la lettre grecque (λ) ; elle est mesurée en mètre ou en l'un de ses sous-multiples.

- La fréquence f : représente le nombre d'oscillations par unité de temps. La fréquence est normalement mesurée en Hertz (Hz), c.à.d. en oscillations par seconde, ou en multiple d'Hertz. Il est à noter que la fréquence d'un rayonnement électromagnétique est invariable, alors que la vitesse de propagation et donc la longueur d'onde peuvent être modifiées lors du passage d'un milieu à un autre. C'est la raison pour laquelle, il vaut toujours mieux caractériser le rayonnement électromagnétique par sa fréquence.

- La période T : c'est le temps au bout duquel le champ électrique ou magnétique retrouve sa valeur à partir d'un instant quelconque, c'est à dire effectue un cycle. L'unité est la seconde.

- La polarisation : c'est à dire l'orientation du champ électrique dans le plan perpendiculaire à la direction de propagation. La lumière visible (rayonnement solaire) est non-polarisée, c'est à dire qu'elle n'a pas d'orientation privilégiée dans ce plan. En revanche, la polarisation du rayonnement doit être prise en compte en télédétection micro-ondes (capteurs passifs et radars).

- L'amplitude de l'onde : qui conditionne l'intensité du rayonnement, plus l'amplitude est forte plus le flux d'énergie est intense.

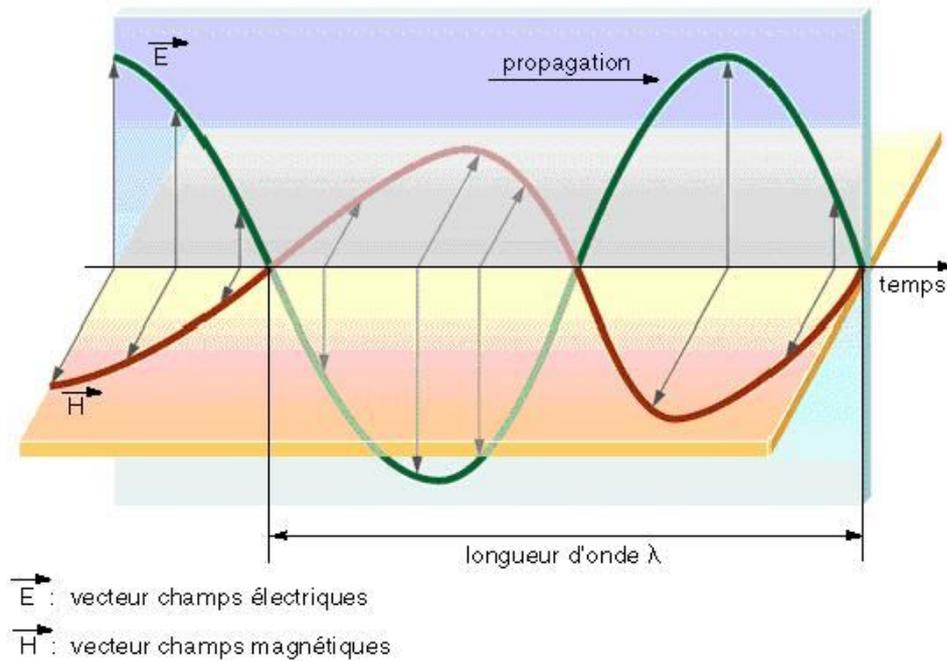


Figure 1.1 : Onde électromagnétique [7]

1-4.1.2 Le spectre électromagnétique

Le rayonnement électromagnétique, d'origine naturelle ou artificielle, existe pour une gamme très étendue de fréquences ou de longueurs d'onde (de 10^{-9}nm à 10^5nm), qui constitue le spectre électromagnétique (figure 1.2). Une partie très limitée de ce spectre, entre $0,390\ \mu\text{m}$ (390 nm) et $0,7\ \mu\text{m}$ (700 nm), constitue la lumière visible à laquelle est sensible l'œil humain. Une décomposition en fonctions des longueurs d'onde de la lumière visible (lumière blanche) aboutit à distinguer les lumières colorées : violet (390 à 450 nm), bleu (450 à 490 nm), vert (490 à 580 nm), jaune (580 à 600 nm), orange (600 à 620 nm) et rouge (620 à 700 nm). Les longueurs d'onde inférieures à 390 nm (ou les fréquences supérieures à celle du violet) ne sont pas perçues par l'œil humain ; il s'agit du rayonnement ultra-violet. De même, les longueurs d'onde supérieures à 700 nm, également non-perçues par l'œil humain, constituent le domaine infrarouge.

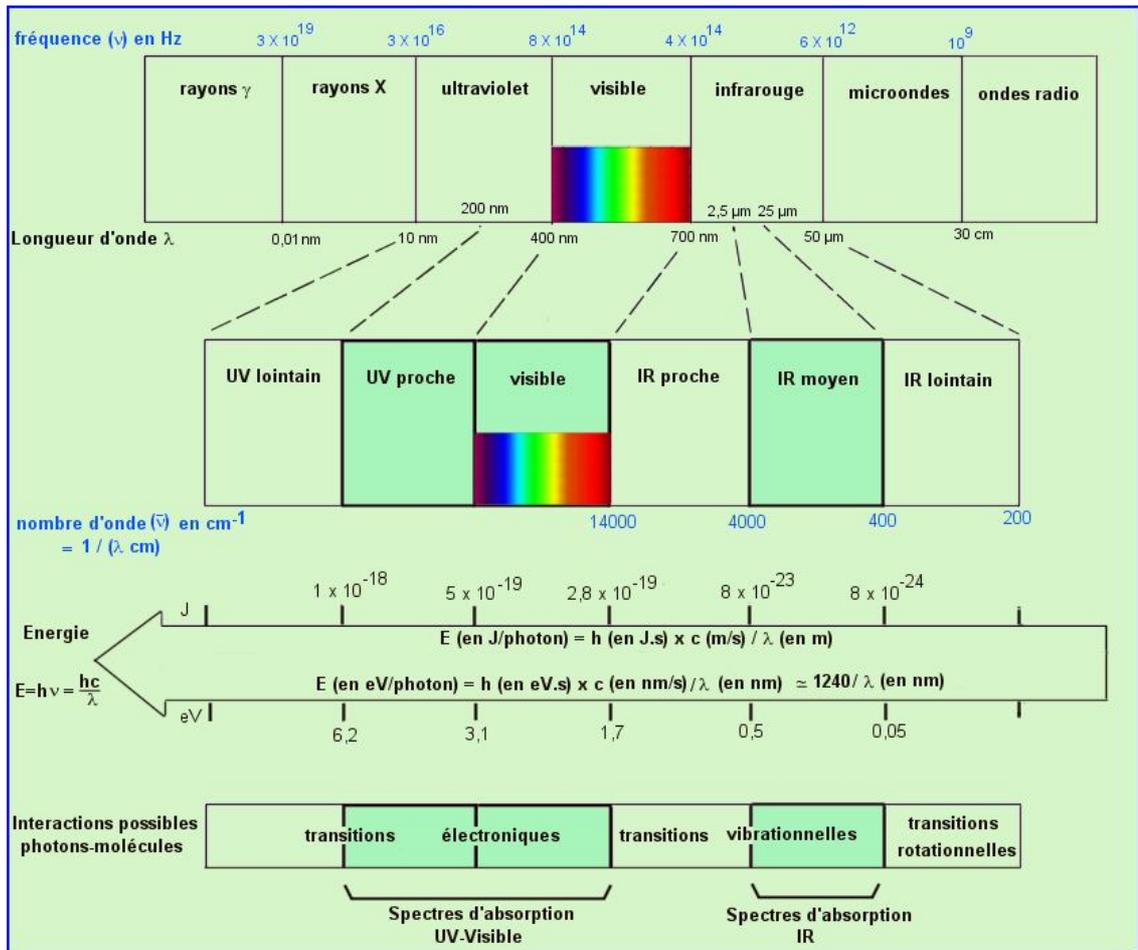


Figure 1.2 : Le spectre électromagnétique et l'énergie correspondante [7]

Les sources du rayonnement varient également selon le domaine du spectre [6]:

- le rayonnement ultraviolet, visible ou infrarouge est émis par les corps, objets ou surfaces en fonction de leur température : rayonnement solaire (U.V, visible et proche infrarouge), rayonnement terrestre (infrarouge thermique).
- les rayonnements de très courte longueur d'onde (rayons gamma, rayons X) sont produits par les restructurations des noyaux des atomes (radioactivité).
- les rayonnements visibles, infrarouge ou microonde peuvent être produits artificiellement par vibration ou rotation des molécules (fluorescence, lasers, four à microondes).
- les rayonnements de grande longueur d'onde sont produits par des oscillations électroniques (antennes).

1.4.1.2 Le rayonnement et l'atmosphère

Lors de son trajet depuis la source (le soleil) vers la cible (surface terrestre), puis de la cible vers le capteur, le rayonnement électromagnétique subit des interactions avec les molécules gazeuses et les particules (aérosols, gouttelettes d'eau, poussières) présentes dans l'atmosphère. Deux phénomènes essentiels se produisent : l'absorption et la diffusion atmosphériques (cf. figure 1.3). Les molécules gazeuses et particules présentes dans l'atmosphère vont provoquer un blocage et/ou une déviation du rayonnement, diminuant ainsi l'énergie transportée par le rayonnement électromagnétique.

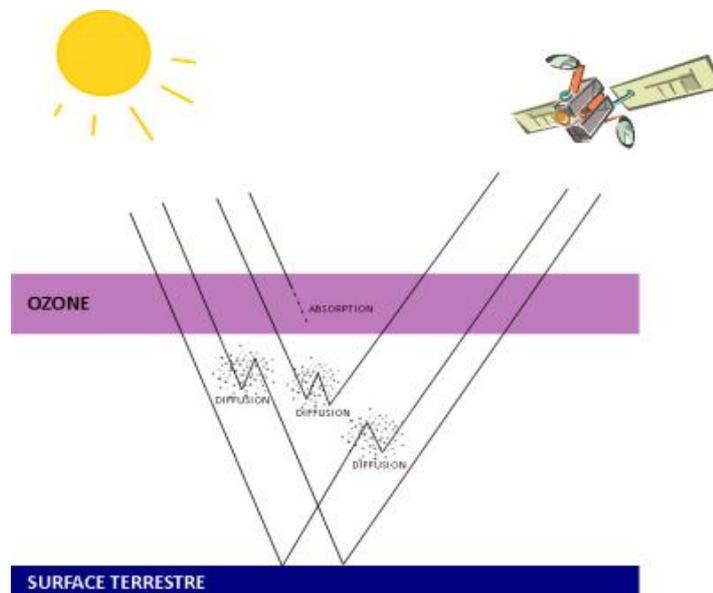


Figure 1.3 : Interactions du rayonnement solaire avec l'atmosphère

Lorsque l'on s'intéresse à l'observation spatiale de la surface terrestre, il est impératif de prendre en compte les interactions rayonnement-atmosphère puisque le signal qui parvient au capteur satellitaire est perturbé par la traversée atmosphérique. À part dans le domaine de la météorologie spatiale où l'on cherche à mesurer la composition et à comprendre les propriétés de l'atmosphère, cet effet perturbateur de l'atmosphère doit être pris en considération dans l'interprétation du signal mesuré par le satellite.

L'absorption atmosphérique

L'absorption survient lorsque les grosses molécules de l'atmosphère (ozone, bioxyde de carbone et vapeur d'eau) absorbent l'énergie de diverses longueurs d'onde. Si l'atmosphère est relativement transparente dans le visible et présente une large fenêtre

atmosphérique dans l'infrarouge (de 8 à 14 μm), elle est opaque de 22 μm à 1mm, ce qui explique la non utilisation de cette portion de spectre en télédétection. Dans les hyperfréquences, l'atmosphère est transparente au-delà de 3cm, mais devient opaque pour des longueurs d'onde supérieures à 30m, pour lesquelles il y a interaction avec l'ionosphère [8].

La diffusion atmosphérique

Lors de sa traversée atmosphérique, le rayonnement peut interagir avec les particules et molécules, présentes dans l'atmosphère, qui constituent des obstacles à la propagation de l'énergie. Lorsque le rayonnement n'est pas absorbé, il peut être en partie dévié dans toutes les directions. C'est le phénomène de diffusion atmosphérique.

Le niveau de diffusion dépend de plusieurs facteurs comme la longueur d'onde, la densité de particules et de molécules, et l'épaisseur de l'atmosphère que le rayonnement doit franchir. Il existe trois types de diffusion [9]:

- la diffusion de Rayleigh
- la diffusion de Mie
- la diffusion non-sélective.

La diffusion de Rayleigh : elle est due aux molécules gazeuses présentes dans l'atmosphère (O₂, N₂, CO₂, vapeur d'eau, etc.) ou aux fines particules de poussière. Elle se produit lorsque la taille des molécules diffusantes est très inférieure à la longueur d'onde du rayonnement. L'intensité diffusée est alors inversement proportionnelle à la puissance 4 de la longueur d'onde du rayonnement incident. La diffusion de Rayleigh est par conséquent un phénomène sélectif qui se produit surtout pour les longueurs d'onde les plus courtes du spectre (violet, bleu).

La diffusion de Mie : lorsque la taille des particules est de l'ordre de grandeur ou plus grande que la longueur d'onde du rayonnement, la diffusion de Rayleigh ne se produit plus et laisse la place à la diffusion de Mie. Les gouttelettes d'eau, les cristaux de glace, ou les aérosols présents dans l'atmosphère (poussières, fumées, pollens) sont les principaux vecteurs de la diffusion de Mie. Beaucoup moins sélective que la diffusion de Rayleigh, la diffusion de Mie est inversement proportionnelle à la longueur d'onde du rayonnement incident.

La diffusion non sélective : elle se produit lorsque la taille des particules atmosphériques est beaucoup plus grande que la longueur d'onde du rayonnement. Elle est due notamment aux gouttelettes d'eau que l'on trouve dans les nuages et les brouillards. La

diffusion non sélective affecte toutes les longueurs d'onde, ce qui explique la couleur blanche des nuages.

1.4.1.3 L'interaction rayonnement /matière

Lorsqu'un rayonnement électromagnétique atteint un objet, certaines longueurs d'onde sont absorbées tandis que d'autres sont réfléchies par l'objet (cf. figure 1.4). Une partie du rayonnement peut éventuellement être transmise à travers l'objet si celui-ci est plus ou moins transparent, avec un changement de direction de la propagation dû à la réfraction. La partie du rayonnement qui est absorbée modifie l'énergie interne de l'objet et produit de la chaleur qui sera réémise sous forme d'un rayonnement à une plus grande longueur d'onde.

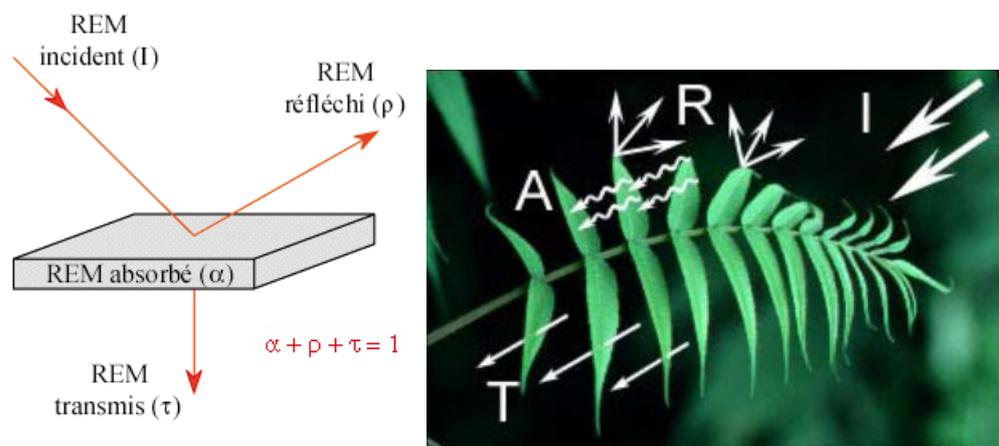


Figure 1.4 : l'interaction rayonnement matière [7]

Tous les objets sont ainsi caractérisés par un coefficient d'absorption (noté α), un coefficient de réflexion (noté ρ), et un coefficient de transmission (noté τ), qui expriment respectivement la part d'énergie absorbée, réfléchie et transmise. Ces trois coefficients ont des valeurs qui varient entre 0 et 1 et leur somme est toujours égale à 1, selon le principe de la conservation de l'énergie [6].

$$\alpha_{\lambda} + \rho_{\lambda} + \tau_{\lambda} = 1$$

Avec :

α_{λ} : coefficient d'absorption à la longueur d'onde λ

ρ_{λ} : coefficient de réflexion à la longueur d'onde λ

τ_{λ} : coefficient de transmission à la longueur d'onde λ

On constate trois phénomènes lors l'interaction rayonnement matière (figure 1.4):

- L'absorption (A) se produit lorsque l'énergie du rayonnement est absorbée par la cible.
- La transmission (T) se produit lorsque l'énergie du rayonnement passe à travers la cible.
- La réflexion (R) se produit lorsque la cible redirige l'énergie du rayonnement.

En télédétection, nous mesurons le rayonnement réfléchi par une cible. La réflexion spéculaire et la réflexion diffuse représentent deux modes limites de réflexion de l'énergie [1]. Une surface lisse produit une réflexion spéculaire, c'est-à-dire que toute l'énergie est redirigée dans une même direction (comme c'est le cas d'un miroir). La réflexion diffuse se produit quand la surface est rugueuse, ce qui redirige l'énergie uniformément dans toutes les directions. La plupart des objets de la surface terrestre se situent entre ces deux extrêmes. La façon dont une cible réfléchit le rayonnement dépend de l'amplitude de la rugosité de la surface par rapport à la longueur d'onde du rayonnement incident. Si la longueur d'onde du rayonnement est beaucoup plus petite que la rugosité de la surface ou que la grosseur des particules qui composent la surface, la réflexion diffuse domine. Par exemple, un sable fin paraît uniforme aux rayonnements à grandes longueurs d'onde, mais rugueux aux longueurs d'onde visibles.

1.4.1.4 Notion de la signature spectrale

Lorsque le soleil éclaire la surface terrestre, des interactions se produisent entre le rayonnement et la cible illuminée. En fonction des propriétés et des caractéristiques de la cible, une partie du rayonnement est réfléchi vers le capteur satellitaire. Chaque objet ou chaque surface possède ainsi une réponse spectrale bien précise à une longueur d'onde donnée. L'ensemble des réponses spectrales à différentes longueurs d'onde constitue ce que l'on appelle la signature spectrale d'une surface. Chaque type de surface peut ainsi être caractérisé et identifié sur une image.

Définition

La signature spectrale (en anglais spectral signature) correspond à l'ensemble des caractéristiques, conditionnant l'interaction du rayonnement électromagnétique avec la matière, nécessaires et suffisantes pour identifier une surface déterminée [10].

En fonction de la nature et des caractéristiques intrinsèques des objets et des surfaces, le rayonnement incident interagira avec la cible selon l'une ou l'autre des propriétés citées précédemment, ou de manière générale selon une combinaison de ces

propriétés. Chaque surface possède ainsi une signature spectrale - quantité d'énergie émise ou réfléchiée en fonction de la longueur d'onde - qui lui est propre et qui permettra son identification sur les images satellitaires. La figure ci-dessous présente la signature spectrale des principales surfaces naturelles.

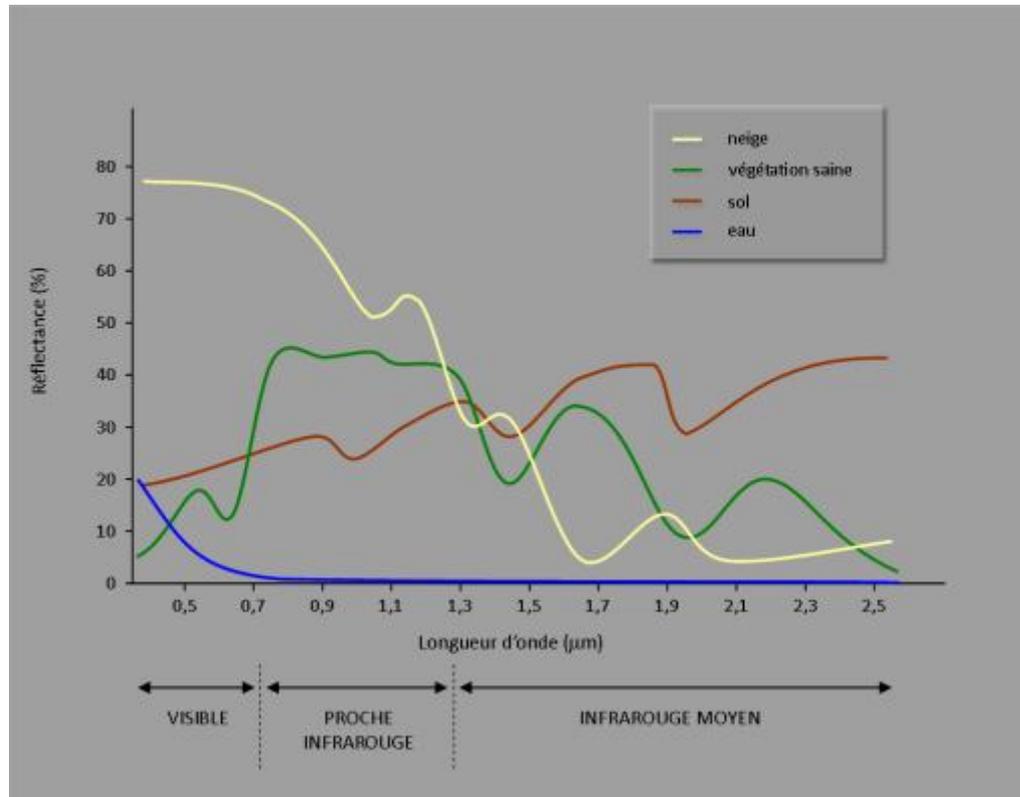


Figure 1.5 : Signatures spectrales des surfaces naturelles dans le domaine du visible, du proche infrarouge et l'infrarouge moyen [11]

1.4.2 Les éléments principaux en télédétection

Le principe de base de la télédétection est similaire à celui de la vision de l'homme. La télédétection est le fruit de l'interaction entre trois éléments fondamentaux : une source d'énergie, une cible et un vecteur.

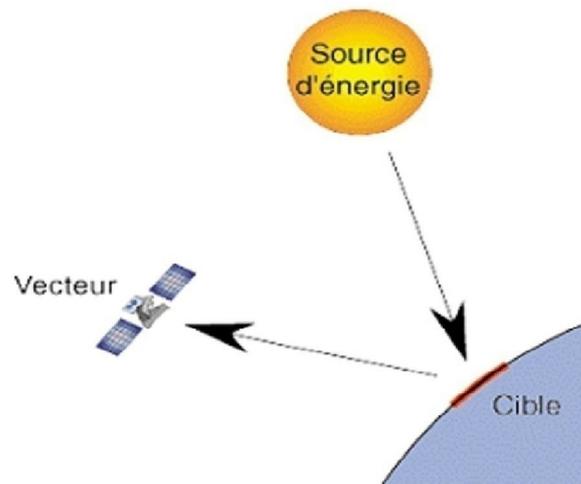


Figure 1.6 : Les éléments principaux de la télédétection

La *cible* : est la portion de la surface terrestre observée par le satellite. Sa taille peut varier de quelques dizaines à plusieurs milliers de kilomètres carrés.

La *source d'énergie* : est l'élément qui éclaire la cible en émettant une onde électromagnétique (flux de photons). En télédétection on trouve deux types de sources d'énergie : le soleil dans le cas de la télédétection passive et une énergie émise par le vecteur dans le cas de la télédétection active (radar).

Le *vecteur* : ou plate-forme de télédétection mesure l'énergie solaire (rayonnement électromagnétique) réfléchi par la cible. Cela peut être un satellite, un avion, un drone, un hélicoptère, ou même un simple cerf-volant !

Il y'a deux types de télédétection :

* *passive* : le vecteur ne fait que capter le rayonnement réfléchi existant.

* *active* : le vecteur émet une onde vers la cible et en mesure l'écho (exemple : radar).

1.4.3 Les étapes de la télédétection

Le processus de la télédétection au moyen de systèmes imageurs comporte les sept étapes que nous élaborons ci-après. Notons cependant que la télédétection peut également impliquer l'énergie émise et utiliser des capteurs non-imageurs [2].

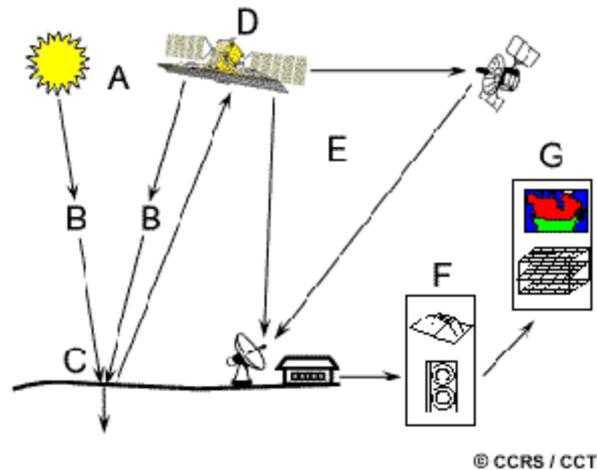


Figure 1.7 : Etapes de la télédétection [2]

1. *Source d'énergie ou d'illumination (A)* : À l'origine de tout processus de télédétection se trouve nécessairement une source d'énergie pour illuminer la cible.
2. *Rayonnement et atmosphère (B)* : Durant son parcours entre la source d'énergie et la cible, le rayonnement interagit avec l'atmosphère. Une seconde interaction se produit lors du trajet entre la cible et le capteur.
3. *Interaction avec la cible (C)* : Une fois parvenue à la cible, l'énergie interagit avec la surface de celle-ci. La nature de cette interaction dépend des caractéristiques du rayonnement et des propriétés de la surface.
4. *Enregistrement de l'énergie par le capteur (D)* : Une fois l'énergie diffusée ou émise par la cible, elle doit être captée à distance (par un capteur qui n'est pas en contact avec la cible) pour être enfin enregistrée.
5. *Transmission, réception et traitement (E)* : L'énergie enregistrée par le capteur est transmise, souvent par des moyens électroniques, à une station de réception où l'information est transformée en images (numériques ou photographiques).
6. *Interprétation et analyse (F)* : Une interprétation visuelle et/ou numérique de l'image traitée est ensuite nécessaire pour extraire l'information que l'on désire obtenir sur la cible.
7. *Application (G)* : La dernière étape du processus consiste à utiliser l'information extraite de l'image pour mieux comprendre la cible, pour nous en faire découvrir de nouveaux aspects ou pour aider à résoudre un problème particulier.

1.5 Conclusion

Dans ce chapitre, nous avons abordé quelques éléments fondamentaux de la télédétection. La définition, l'histoire, la technologie, les systèmes opérationnels et les caractéristiques des systèmes ont été décrits. La connaissance des caractéristiques des données, nous permettra de connaître les potentialités de la télédétection et les moyens qu'elle fournit en vue de son application (identification, cartographie des objets terrestres, ...).

CHAPITRE 2

Acquisition, Traitement et Application des images de télédétection

2.1 Introduction

Après avoir vu le principe de la télédétection, nous allons présenter dans ce chapitre l'apport de la télédétection à travers l'image satellitaire en passant en revue toutes les étapes depuis l'acquisition jusqu'à l'application. Ainsi, nous abordons dans la section 2.2 les caractéristiques d'un satellite d'observation de la terre ; nous décrivons la résolution et la fauchée... La section 2.3 sera consacrée à l'image satellitaire et aux différentes notions qui lui sont liées comme la bande spectrale et la composition colorée. La section 2.4 quant à elle expose les différents traitements et analyses effectués sur les images satellitaires. Dans la section 2.5, nous présentons les applications de l'imagerie satellitaire de façon générale ; nous détaillons en particulier le concept dit occupation du sol puisque il est fortement lié au thème de notre recherche.

2.2 Les satellites de la télédétection

L'observation de la terre par satellite résulte de plusieurs efforts qui se sont développés depuis la fin du 19^{ème} siècle avec le lancement des fusées. Ce n'est qu'en 1960 que la première série de satellites météorologiques a commencé avec TIROS. Plusieurs autres satellites ont été ensuite mis en orbite, à des fins notamment météorologiques. En 1967, la NASA avec la coopération de l'U.S. Département de l'Intérieur a pris l'initiative de développer des satellites d'observation des ressources de la terre. Ceci a abouti au lancement du satellite ERTS-1 le 23 juillet 1972 qui a été ensuite rebaptisé LANDSAT 1, 2,3. À partir des années 70, plusieurs autres satellites ont été lancés pour diverses applications (NOAA, GOES, SAR, etc.). Le 2 février 1986 le gouvernement français a lancé le premier satellite de la série SPOT [10].

2.2.1 Les caractéristiques d'un satellite

Les capteurs peuvent être placés sur différentes plates-formes. Bien que les plates-formes terrestres ou aéroportées soient utilisées, ce sont les satellites qui fournissent la majeure partie des données recueillies par télédétection de nos jours. Certaines caractéristiques propres aux satellites en font des instruments particulièrement utiles pour l'acquisition d'information sur la surface de la Terre.

2.2.1.1 L'orbite

Elle correspond à la trajectoire effectuée par un satellite autour de la Terre. L'orbite d'un satellite est choisie en fonction de la capacité des capteurs qu'il transporte et des objectifs de sa mission. Le choix d'une orbite est déterminé par l'altitude (la hauteur du satellite au-dessus de la surface de la Terre), l'orientation et la rotation du satellite par rapport à la Terre. On distingue différents types d'orbites [12]

Orbites Géostationnaires

Une orbite géostationnaire (GEO=géosynchrone) est une orbite au cours de laquelle le satellite est toujours dans la même position par rapport à la Terre en rotation. Les orbites du satellite se font alors à une altitude de 36,000 km approximativement pour que la période de l'orbite (temps écoulé lors d'une orbite) soit égale à la période de rotation de la Terre (23 hrs, 56 mins, 4.09 secs). Ainsi en tournant à la même vitesse et dans la même direction que la Terre, le satellite apparaît stationnaire (synchrone par rapport à la rotation de la Terre). Les Satellites géostationnaires donnent des vues "grand angle" de la Terre. Ils permettent ainsi de localiser les événements météos. Cela est très utile pour relever les gros orages locaux et les cyclones tropicaux. Une orbite géostationnaire doit se trouver dans le même plan que celui de rotation de la Terre, c'est-à-dire le plan équatorial ; elle fournit des images distordues des régions polaires avec une faible résolution.

Orbites Polaires

Les satellites à orbites polaires donnent une vue plus globale de la Terre. Ils tournent autour de la Terre avec une inclinaison proche des pôles (l'angle entre le plan équatorial et le plan d'orbite du satellite, une vraie orbite polaire a une inclinaison de 90 degrés). Ils se trouvent à une altitude de 700 à 800 km, et ils couvrent le mieux les parties de la Terre qui sont difficiles d'accès. Par exemple, McMurdo, dans l'Antarctique, peut être vu 11 à 12 fois sur 14 passages journaliers de l'instrument à orbites polaires. Ces satellites ont des orbites héliosynchrones, ils fournissent par balayage de la Terre des vues éclairées par le soleil. Les passages de ces satellites se font au-dessus de l'équateur et de chaque latitude à la même heure chaque jour, ce qui signifie que le satellite passe au-dessus de nous à la

même heure solaire tout le long des saisons de l'année. Cette caractéristique permet de relever régulièrement les données de façon consistante ainsi que de faire des comparaisons. Le plan de l'orbite d'un satellite héliosynchrone doit également tourner d'un degré par jour approximativement pour avoir la même allure que la surface de la Terre.

Orbites Inclinées

Les orbites inclinées tombent dans la catégorie qui se trouve entre les orbites géostationnaires et les orbites polaires. Elles ont une inclinaison entre 0 degré (orbite équatoriale) et 90 degrés (orbite polaire). Ces orbites peuvent être déterminées selon la région sur Terre à laquelle on est le plus intéressé (par exemple, un instrument qui étudie les tropiques a intérêt à être mis sur un satellite à faible inclinaison), ou selon la latitude du site de lancement. L'altitude de ces satellites est généralement de l'ordre de quelques centaines de km, de telle façon que la période de l'orbite soit de l'ordre de quelques heures. Ces satellites ne sont pas héliosynchrones, ils voient donc la même région sur Terre à des heures qui varient.

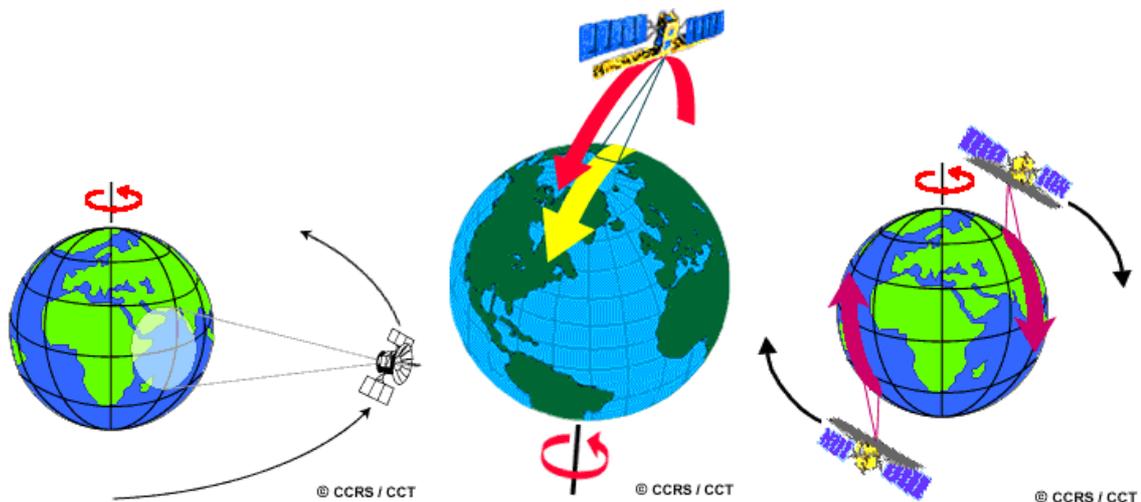


Figure 2.1 : Les orbites des satellites

(a) Géostationnaire-(b) Polaire-(c) Inclinée [2]

2.2.1.2 la fauchée

Lorsqu'un satellite est en orbite autour de la Terre, le capteur "observe" une certaine partie de la surface. Cette surface porte le nom de couloir-couvert ou fauchée. Les capteurs

sur plate-forme spatiale ont une fauchée dont la largeur varie généralement entre une dizaine et une centaine de kilomètres.

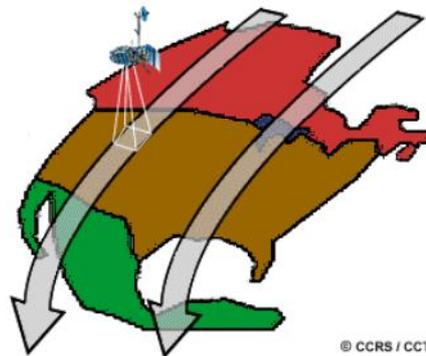


Figure 2.2 : La fauchée d'un satellite

2.2.1.3 Notion de la résolution

La résolution est un terme souvent utilisé pour déterminer, soit le nombre de pixels que l'on peut afficher ou alors la surface du sol qu'un pixel représente dans un fichier image. Ces larges définitions sont inadéquates. Quand il s'agit de décrire des données d'images satellitaires, on distingue, quatre sortes de résolutions, à savoir (figure.2.3).

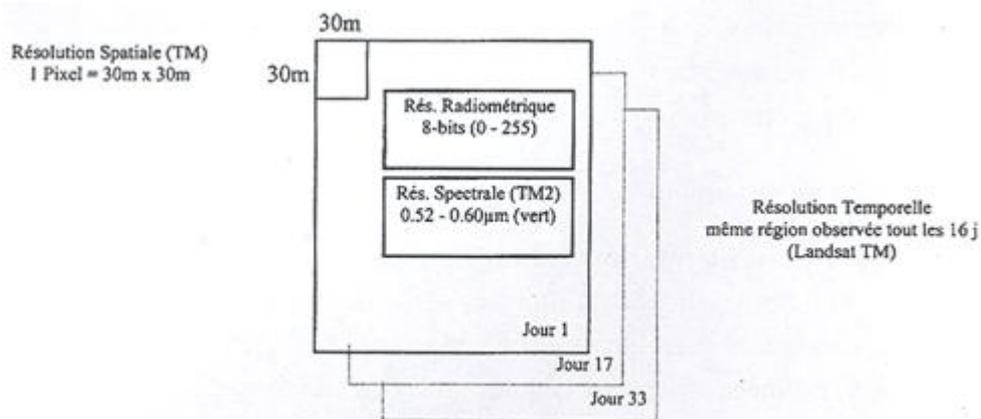


Figure 2.3 : Les 4 types de résolution

- La *résolution spectrale* : qui se rapporte aux intervalles spécifiques des longueurs d'ondes dans le spectre électromagnétique qu'un capteur puisse enregistrer. Plus l'intervalle est large dans le spectre électromagnétique, plus la résolution spectrale est petite et vice-versa. Par exemple, le capteur SPOT-P est considéré comme ayant un spectre de résolution spectral grossier puisqu'il enregistre la radiation électromagnétique REM entre 0.51 et 0.73

mm tandis que le senseur Landsat TM3 lui, a une résolution plus fine, car il enregistre le REM entre 0.63 et 0.69 mm [10].

- La *résolution spatiale* : qui représente la mesure des objets les plus petits discernés par le senseur ou alors la surface du sol représentée par chaque pixel . Chaque nombre ou valeur dans le fichier image est appelé pixel qui est la plus petite partie d'une image avec une seule valeur. Cette dernière représente la mesure de la brillance du pixel à une certaine longueur d'onde [10].

- La *résolution radiométrique* : qui se réfère au rayon d'action dynamique ou le nombre possible de valeurs dans chaque bande, et ce, par le nombre de bits par lequel l'énergie enregistrée est répartie dans le fichier image. Par exemple, des données 8-bits sont celles ayant 2^8 valeurs, soit 256 niveaux de brillances allant de 0 à 255 [10].

- La *résolution temporelle* : qui se rapporte à la fréquence d'un senseur à obtenir une image d'une région particulière. Par exemple, le satellite Landsat peut prendre des images de la même région tous les 16 jours, alors que SPOT peut le faire tous les jours, grâce à la technique de visée latérale [10].

2.2.2 Le satellite LANDSAT

À ce jour, la série des satellites Landsat comporte six satellites. Les trois premiers étaient équipés de scanners multispectraux (MMS) d'une résolution spatiale de 80 mètres et d'une résolution spectrale de 4 canaux dans les plages visible et quasi-infrarouge. En outre, les satellites Landsat 4 et 5 sont équipés d'un « Thematic Mapper » (TM), qui possède sept canaux, dont un dans l'infrarouge thermique. La résolution spatiale est de 30 mètres. Autrement dit, chaque pixel correspond à une surface de 30m x 30m sur la surface de la Terre. Du fait de leur résolution spectrale élevée, les tous derniers satellites Landsat ont été considérés comme dotés des meilleurs capteurs pour le classement des zones et ont largement contribué au développement de ce domaine. Ils sont équipés de trois canaux dans le spectre visible (bleu, vert et rouge) et de trois canaux dans le proche infrarouge, où l'atmosphère est la plus translucide [13].

2.2.3 Le satellite SPOT

Décidé en 1978 par la France, le programme Spot (Système Probatoire d'Observation de la Terre ou Satellite Pour l'Observation de la Terre) est réalisé par le CNES (Centre national

d'études spatiales) en collaboration avec la Belgique et la Suède. Il est composé d'une série de satellites et d'infrastructures terrestres pour le contrôle et la programmation des satellites ainsi que pour la production des images [35].

* Orbite : quasi polaire, circulaire, héliosynchrone.

* Altitude : 822 km.

Un des grands atouts du système SPOT est sa capacité de dépointage de son instrument imageur principal de part et d'autre de la trace au sol du satellite, de $+31,06^\circ$ à $-31,06^\circ$. Ceci lui confère une très grande flexibilité d'acquisition, en ramenant notamment la répétitivité d'acquisition (fréquence temporelle ou fréquence de revisite) à 2-3 jours.

1^{ère} génération : *Spot 1, 2, 3*

Résolution des images de l'instrument HRV (Haute Résolution Visible) :

10 mètres en panchromatique (canal couvrant le domaine visible du spectre électromagnétique)

20 mètres en multispectral (trois bandes dans le vert, le rouge et l'infrarouge proche)

Lancement :

Spot-1, lancé le 22 février 1986 (Ariane 1)

Spot-2, lancé le 22 janvier 1990 (Ariane 40)

Spot-3, lancé le 26 septembre 1993 (Ariane 40), fin de fonctionnement en novembre 1996)

2^{ème} génération : *Spot-4*

Résolution des images de l'instrument HRVIR (Haute Résolution Visible et Infrarouge) :

10 mètres en monospectral dans le canal rouge, SPOT4 ne dispose pas d'un véritable panchromatique,

20 mètres en multispectral (quatre bandes dans le vert, le rouge, l'infrarouge proche et le moyen infrarouge)

Lancement :

Spot-4 a été lancé le 23 mars 1998 (Ariane 40, Vol 107)

3^{ème} génération : *Spot-5*

Résolution des images de l'instrument HRG (Haute Résolution Géométrique):

L'innovation de Spot-5 est l'introduction du Super-Mode qui permet la création d'une image à 2,5 mètres de résolution à partir de deux images à 5 mètres acquises simultanément avec un demi-pixel de décalage. Leur combinaison est réalisée par des techniques de traitement et de restauration d'image avancées.

2,5 mètres en super-mode panchromatique

5 mètres en panchromatique

10 mètres en couleur

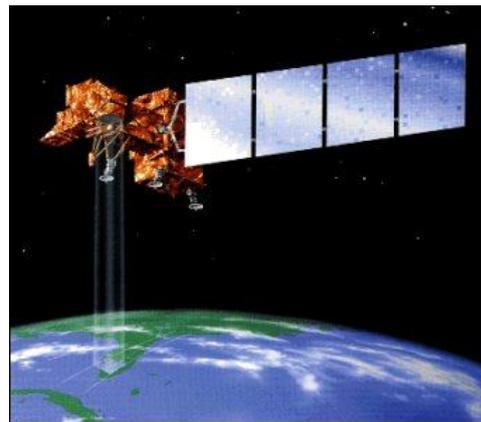
Capacités d'acquisition de couples stéréoscopiques améliorées grâce à l'instrument HRS (Haute Résolution Stéréoscopique)

Lancement :

Spot-5 a été lancé le 3 mai 2002 (Ariane 42P, Vol 151)



LANDSAT5



SPOT

Figure 2.4: Les satellites d'observation de la terre

2.3 Les images satellitaires

L'utilisation de l'ordinateur dans la phase du traitement et de l'analyse des images nécessite une représentation des données images sous format numérique. Une définition mathématique d'une image est essentielle afin de bien comprendre le terme image numérique.

Une image de télédétection est une représentation plane (bidimensionnelle) de la distribution du rayonnement électromagnétique (REM) réfléchi ou émis par des objets. Les variations du REM dans l'espace sont traduites sur cette image par des variations de la teinte de gris, et perçues par l'homme comme des variations de brillance. Ces variations de brillance créent la sensation visuelle du contraste, de la texture et de la forme des objets. Les variations de la teinte de gris sur l'image acquise à un moment t et à une longueur d'onde λ sont intimement liées aux variations de l'énergie rayonnée par la scène. Nous pouvons donc décrire une image par la fonction $f(x, y, t, \lambda)$. La valeur de f aux coordonnées spatiales (x, y) donne l'intensité (brillance) de l'image à ce point. Puisque f

dépend de l'énergie rayonnante, elle n'est jamais négative. Par ailleurs, le système de prise d'image impose une limite supérieure à la fonction f . Cette limite est appelée le niveau de saturation :

$$0 < f(x, y, t, \lambda) < A,$$

Où A est le niveau de saturation.

L'intervalle $(0, A)$ est appelé le rang dynamique ou échelle de gris et une valeur particulière de f à l'intérieur de cet intervalle est appelée niveau de gris.

Les images perceptibles par l'ordinateur se présentent comme un arrangement de chiffres exprimés sous un code lisible par l'ordinateur (code binaire). En termes mathématiques, cet arrangement de chiffres s'appelle une matrice. Chaque élément de cette matrice est appelé pixel.

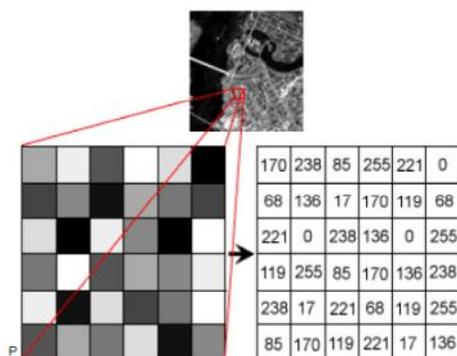
En termes de télédétection, chaque pixel représente la plus petite partie discernable du sol avec des coordonnées précises. La valeur assignée à ce pixel représente l'enregistrement de la réflectance de la surface terrestre aux coordonnées précitées.

2.3.1 Notion de bandes

Les données images comprennent un certain nombre de bandes d'information (figure 2.5).

Chaque bande est une sorte de fichier de données, soit pour :

- une portion spécifique du spectre électromagnétique : rouge, vert, bleu, proche infrarouge
- d'autres informations créées comme les Modèles numériques d'Altitude (MNA)
- la combinaison ou le rehaussement de la bande originale
- la création de nouvelles bandes à partir d'autres sources.



Représentation matricielle



les bandes spectrales

Figure 2.5 Image satellitaire

2.3.2 Compositions colorées

Dans les systèmes de télédétection, nous avons vu qu'il est possible de détecter et d'enregistrer des parties du spectre électromagnétique qui ne sont pas décelables à l'œil nu, comme l'infrarouge par exemple. Pour pouvoir visualiser cette information, on associe aux bandes spectrales du système d'observation des couleurs d'affichage (rouge-vert-bleu), qui ne leur correspondent pas nécessairement. Ce faisant, on crée des compositions colorées, appelées parfois "images en fausses couleurs" [14]

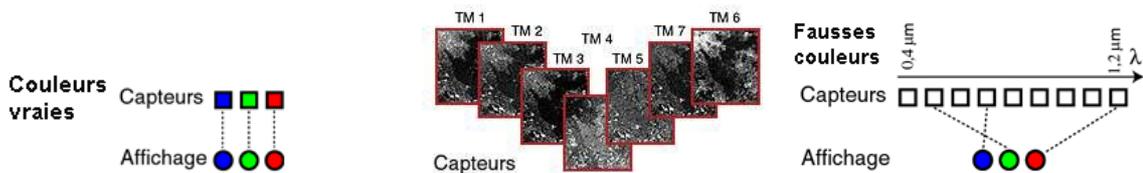


Figure 2.6 : Création d'image en fausse couleurs

Cette méthode est très efficace car elle permet d'analyser en un coup d'œil des données ayant trois composantes. En faisant varier de 0 à 255, les composantes rouges, verte et bleue définissant la couleur d'un pixel d'une image numérique, on peut obtenir plus de 16 millions de couleurs différentes. L'œil de l'interprète s'avère être un puissant outil d'analyse, car il permet de comparer la couleur de différents objets, mais aussi d'analyser la manière dont les couleurs sont juxtaposées, la forme et la taille des objets, etc.

Cette possibilité est à la base des techniques de photo-interprétation des images de télédétection.

2.4 Traitement et analyse des images de télédétection

Quand des données de télédétection sont disponibles en format numérique, le traitement et l'analyse numériques peuvent être faits au moyen d'un ordinateur. Le traitement peut servir à rehausser les données en prévision d'une interprétation visuelle. Des traitements et analyses numériques peuvent être faits automatiquement afin d'identifier des cibles et d'extraire l'information sans l'intervention d'un interprète humain. Cependant, le traitement et l'analyse numériques sont presque toujours utilisés en appui et en complément à l'interprétation humaine.

2.4.1 Prétraitement

On appelle fonctions de prétraitement les opérations qui sont normalement requises avant l'analyse principale et l'extraction de l'information. Les opérations de prétraitement se divisent en corrections radiométriques et en corrections géométriques. Les corrections radiométriques comprennent entre autres, la correction des données à cause des irrégularités du capteur, des bruits dûs au capteur ou à l'atmosphère, et de la conversion des données afin qu'elles puissent représenter précisément le rayonnement réfléchi ou émis mesuré par le capteur. Les corrections géométriques comprennent la correction pour les distorsions géométriques dues aux variations de la géométrie Terre-capteur, et la transformation des données en vraies coordonnées (par exemple en latitude et longitude) sur la surface de la Terre.

2.4.2 Rehaussement de l'image

Le rehaussement de l'image est le processus qui permet de rendre une image plus facile à interpréter pour une application donnée [12] [10]. Les fonctions de rehaussement ont pour but d'améliorer l'apparence de l'imagerie pour aider l'interprétation et l'analyse visuelles. Les fonctions de rehaussement permettent l'étirement des contrastes pour augmenter la distinction des tons entre les différents éléments d'une scène, et le filtrage spatial pour rehausser (ou éliminer) les patrons spatiaux spécifiques sur une image.

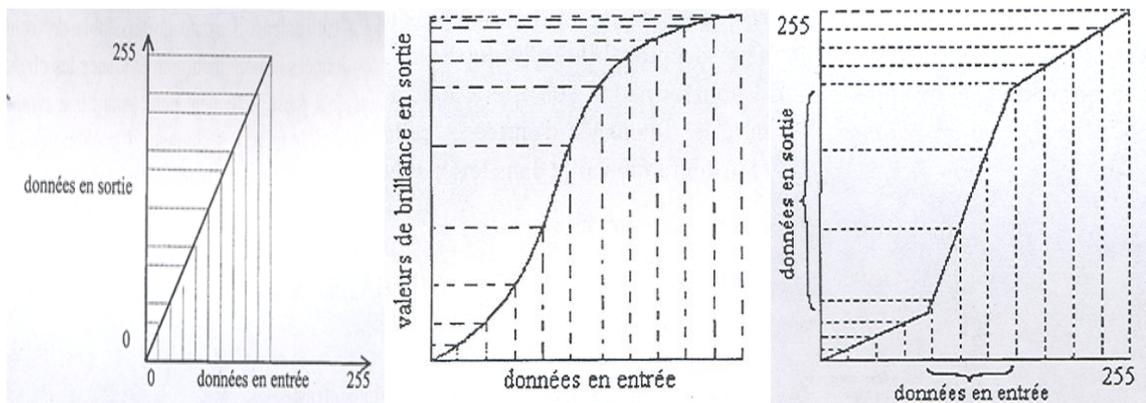
2.4.2.1 Amélioration du contraste

Il s'agit d'une technique très simple, utilisée pour faciliter l'interprétation des images. Elle consiste à appliquer une transformation, linéaire ou non linéaire, à l'amplitude du signal de chacun des pixels d'une image pour que l'ensemble des amplitudes occupe plus efficacement l'échelle de gris disponible (en général de 0 à 255). On peut diviser les algorithmes en deux classes :

- Les fonctions mathématiques directes : ce sont des algorithmes simples qui modifient les valeurs des intensités suivant une relation mathématique indépendante de la densité de probabilité d'occupation des niveaux de gris.
- Les fonctions statistiques : ces algorithmes nécessitent au préalable une mesure de la densité de probabilité d'occupation des niveaux de gris (histogramme). La transformation consistera donc à établir une table de correspondance entre les intensités d'entrée et celles de sortie de telle sorte que le nouvel histogramme aille dans le sens recherché.

Il existe trois types d'étalement du contraste :

- *l'étalement linéaire du contraste* : c'est une façon simple d'améliorer le contraste visible d'une image. Dans l'exemple de la figure 2.7, on remarque que l'intervalle de valeurs d'entrées est étroit, tandis que les valeurs en sortie, de quelques pixels, sont étalées au-dessus d'un intervalle plus large.



L'étalement linéaire l'étalement non linéaire l'étalement linéaire par paliers

Figure 2.7 : Les trois types d'étalement de contraste

- *l'étalement non linéaire du contraste* : cette technique est souvent utilisée pour augmenter ou diminuer le contraste d'une image de manière graduelle sur un intervalle donné, au lieu d'appliquer un étalement de contraste sur la totalité des données à travers l'image. Souvent, ce type de rehaussement met en évidence le contraste dans un intervalle et le réduit dans un autre (Figure 2.7).

- *l'étalement linéaire par paliers* "Piecewise linear contrast stretch" : cette méthode d'étalement du contraste permet le traitement d'une portion bien précise de données en divisant la table de conversion (Lookup Table ou LUT) en trois sections : une section basse, une section moyenne et une section haute. Ce type d'étalement permet de créer un nombre de segments droits simulant une courbe représentant la LUT. Ainsi, on peut traiter le contraste de chaque section (ou portion de l'image) en même temps (Figure 2.7).

2.4.2.2 Filtrage des images

On entend par filtrage toute technique visant à éliminer le bruit contenu dans les données. En théorie de l'information, le bruit est toute donnée non utile qui masque l'information. Ce bruit peut provenir de deux sources différentes :

- soit du système de mesure, de transmission ou de support des données. Nous distinguons le bruit de quantification, la réponse inégale des détecteurs, le temps de réponse imparfait du détecteur, le bruit de transmission, etc.

- soit des sources externes à l'objet observé, comme l'atmosphère, le relief ou l'antenne pour les micro-ondes, etc.

Pour certaines applications, et en particulier en géologie, on est davantage intéressé à la découverte dans l'image de discontinuités dans les textures qu'à la définition des objets eux-mêmes. On s'intéresse par exemple aux contours de zones relativement homogènes, ce qui peut révéler la présence de failles ou de fractures.

2.4.3 Transformations d'images

Les transformations d'images sont des opérations similaires à ceux de rehaussement de l'image. Cependant, alors que le rehaussement de l'image est normalement appliqué à une seule bande de données à la fois, la transformation de l'image combine quant à elle le traitement des données de plusieurs bandes spectrales. Des opérations arithmétiques (c'est-à-dire addition, soustraction, multiplication, division) sont faites pour combiner et transformer les bandes originales en de "nouvelles" images qui montrent plus clairement certains éléments de la scène [10].

2.4.4 Classification multispectrale

La classification multispectrale est le procédé de tri des pixels en un nombre limité de classes individuelles ou catégories de données basées sur les mêmes critères. Si pour chaque objet au sol on possède un ensemble de M composantes images différentes, il est possible à partir des mesures de ces objets pour identifier la classe à laquelle appartient chacun des objets contenus dans la scène analysée, suivant une approche où l'exactitude des résultats comme la précision de la méthode peuvent être évaluées statistiquement [8].

En télédétection, on cherche souvent à reconnaître la signature ou enveloppe des vecteurs associés à une classe par des mesures spectrales. On parle alors de signature spectrale. Cette dernière peut être unique. Cependant, le plus souvent, elle regroupe partiellement d'autres signatures : il est alors plus difficile de choisir l'étiquette qui lui convient le mieux en minimisant autant que possible les risques d'erreur[10]. Ce processus d'analyse, visant la création d'images thématiques, se prête bien à un traitement par ordinateur. En effet, une

fois les critères de classification établis, l'ordinateur peut les appliquer rapidement pour déterminer la classe de chacun des nombreux éléments des images [15].

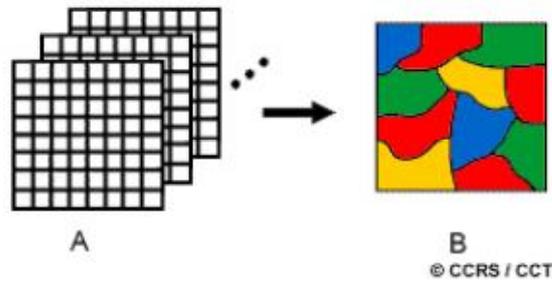


Figure 2.8 : La classification multispectrale

On distingue deux types de méthodes de classification [10]: les méthodes supervisées (ou avec professeur) et les méthodes non supervisées (ou sans professeur):

2.4.4.1 Classification supervisée

Elle se pratique si les domaines des classes sont connus a priori. Toutes les méthodes supervisées comprennent deux phases : la phase d'entraînement et la phase de classification. Lors de la première phase, à l'aide d'échantillons de pixels dont la classe d'appartenance est connue, on établit des zones d'entraînement pour chaque classe. Une zone d'entraînement, est une zone de l'image dont l'occupation du sol est connue de l'utilisateur. Dans la seconde phase, on classe les pixels de l'ensemble de l'image par comparaison de chaque pixel avec les domaines connus. La procédure assigne à chacun des pixels de l'image l'une des catégories d'occupation du sol. Cette méthode présente un grand avantage, du fait que la classification peut alors être standardisée car elle est indépendante de la zone et de la méthode utilisée. Par contre le principal inconvénient est que cette méthode est rigide, c'est à dire qu'il est impossible de rajouter une classe, et que dans certains cas il n'est pas facile d'attribuer à une parcelle le nom d'une classe prédéfinie [10].

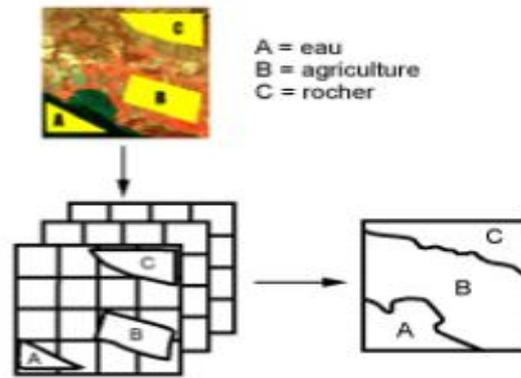


Figure 2.9 : classification supervisée

2.4.4.2 Classification non supervisée

Elle se pratique si les domaines des classes sont inconnus. On cherche alors à établir des groupements de vecteurs de mesure dans l'espace de représentation en utilisant des critères mathématiques ou statistiques de ressemblance des valeurs considérées comme les domaines des classes. Une fois l'attribution des pixels de l'image complétée, la signification réelle de chaque classe reste alors à établir. Elle utilise des algorithmes d'analyse par regroupement. Ces algorithmes déterminent automatiquement des signatures et les classifient [15]. Les avantages de cette méthode sont sa flexibilité et son adaptabilité [10].

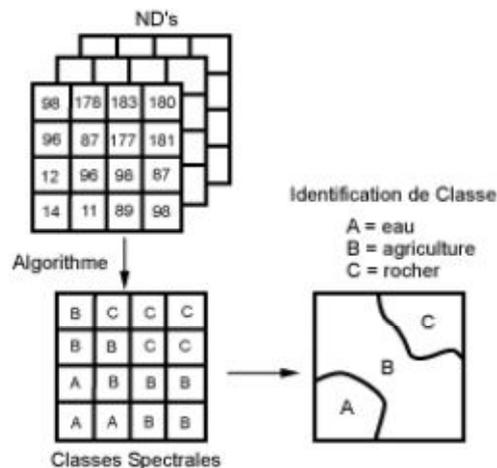


Figure 2.10 : classification non supervisée

2.5 Les application de l'imagerie satellitaire

Les images satellite sont très riches en informations de toutes sortes. L'information obtenue par les images satellite permet non seulement de fabriquer et de mettre à jour des cartes, mais elle permet aussi d'analyser divers aspects du territoire. Les images satellites

ne sont généralement pas aussi précises que les photographies aériennes, mais elles couvrent de grands territoires et permettent des analyses régionales. Parmi les nombreuses applications, nous pouvons citer en particulier [12] [10]:

➤ **Agriculture**

L'imagerie par satellite permet aux producteurs agricoles d'obtenir de l'information sur leur territoire afin de gérer plus efficacement les récoltes.

Cette technologie leur permet de planifier les opérations et de prévoir les risques pouvant menacer leur production. Par exemple, ils peuvent s'en servir pour prévoir les risques liés aux infestations d'insectes, aux intempéries, aux sécheresses, etc. En agriculture, les images satellite servent, entre autres, à :

- *classifier les grands types de culture ;*
- *évaluer la santé des cultures ;*
- *estimer la production totale d'une récolte ;*
- *cartographier les pratiques de gestion du sol ;*
- *surveiller la conformité aux lois et aux traités.*

➤ **Foresterie**

Les images satellite sont utilisées pour obtenir de l'information sur les types de couvert forestier (inventaire des grands groupes et parfois des espèces), sur la densité de la végétation et sur la diminution ou l'état de la régénération des ressources.

Elles servent aussi à observer les récoltes réalisées et permettent de veiller sur la qualité, la santé et la diversité des forêts. Ces outils sont très utiles pour la gestion des ressources forestières et pour l'amélioration de la cartographie portant sur le sujet.

➤ **Géologie**

Dans ce domaine, les études portent sur les formes de terrain, les structures et l'écorce terrestre afin de faciliter la compréhension des processus physiques qui modifient la croûte terrestre.

L'image satellite est un outil intéressant dans ce domaine, puisqu'elle permet d'extraire l'information sur la structure par exemple, les failles et les plis. Cette information est souvent combinée à d'autres sources de données pour obtenir des mesures complémentaires.

L'image satellite permet aussi de planifier et de faire de la logistique, par exemple la planification de campagnes de terrain ou de routes d'accès dans une région minière, la

surveillance de projets et la création de cartes de base sur lesquelles les données géologiques peuvent être superposées.

Voici une liste non exhaustive des principales applications des images satellite en géologie :

- *la cartographie des dépôts de surface;*
- *l'exploration minière et pétrolière;*
- *la géologie environnementale;*
- *la cartographie et la surveillance.*

➤ **Risques naturels et industriels**

Dans la gestion des risques, les applications consistent à :

- *mettre à jour les plans de prévention des risques ;*
- *localiser rapidement les zones affectées et cartographier les dégâts ;*
- *améliorer les modèles de prévision et de simulation des phénomènes à risques ;*
- *... etc.*

➤ **Aménagement du territoire et études urbaines**

Les études menées dans ce contexte concernent :

- *l'occupation du sol ;*
- *les études d'impact sur l'environnement ;*
- *le suivi de l'urbanisation.*

➤ **Surveillance maritime**

Dans le domaine maritime, les applications consistent notamment à :

- *contrôler les activités de pêche et du trafic maritime ;*
- *localiser les nappes de pollution ;*
- *gérer l'environnement côtier et océanique.*

➤ **Météorologie, océanographie et hydrographie**

Les études menées concernent :

- *le calcul du niveau de la mer et des lacs ;*
- *la bonne connaissance des marées ;*
- *la mesure de la hauteur de vagues (Topex Poséidon) ;*
- *la topographie des glaces marines (banquise et icebergs).*

2.6 Carte d'occupation et d'utilisation du sol

Les termes d'utilisation et d'occupation du sol sont, avec le développement de la télédétection et les SIG (Systèmes d'Information Géographiques) régulièrement utilisés dans les études de géographie. Bien que les termes occupation et utilisation du sol soient intrinsèquement liés, leur sémantique est sensiblement différente ce qui implique de les définir précisément. Souvent perçus comme plus ou moins semblables, des divergences d'interprétation de ces termes peuvent rendre parfois complexe l'interprétation de certains résultats relatifs à l'évolution de la couverture végétale dérivés par exemple de données de télédétection ou de données produites par des modèles de type prédictif.

D'une façon générale, l'occupation du sol fait référence aux propriétés physiques de la surface terrestre alors que l'utilisation du sol fait appel aux fonctions économiques et sociales de celle-ci.

Plus précisément, trois différences sémantiques principales peuvent être identifiées entre les termes « utilisation » et « occupation » du sol [1] :

- ✓ La première concerne les définitions des classes de ces deux termes. L'occupation du sol peut être définie comme une observation physique à un instant « t » de la surface terrestre, incluant la végétation (naturelle ou artificielle) et les constructions humaines. L'utilisation du sol, elle, implique de connaître la manière dont sont agencés les attributs biophysiques du sol et le but poursuivi par cette gestion du territoire. L'utilisation du sol fait ainsi référence au comportement humain et plus spécifiquement aux contraintes économiques qui régissent l'exploitation et la gestion d'un territoire.

- ✓ La seconde différence tient à l'expression géométrique entre les deux termes. L'occupation du sol fait ainsi référence à un état biophysique d'un endroit précis ou à un espace homogène du paysage (par exemple, une parcelle agricole). En revanche, l'utilisation du sol fait référence à la fonction économique d'une unité spatiale en définissant par exemple le nom du propriétaire de la parcelle.

- ✓ La dernière différence repose sur les règles d'affectation des attributs pour chaque unité spatiale [1]. A ce niveau, de nombreuses confusions apparaissent car les termes d'utilisation et d'occupation du sol ne sont pas toujours bien définis au préalable. La définition des classes concernant l'occupation du sol est basée sur l'état du couvert végétal à un instant précis sur une portion d'un espace géographique. On retrouvera par exemple comme classes d'occupation du sol caractérisant un territoire, les classes « arbres », « bâti » « eau »,... Concernant les classes attribuées à l'utilisation du sol, celles-ci doivent fournir une information précise sur l'activité menée sur un espace géographique. Ainsi, les

attributs appropriés pour définir l'utilisation du sol d'une portion d'un territoire rural seraient par exemple « forêt », « bâti résidentiel », « canal »...

Les termes d'occupation et d'utilisation du sol bien que similaires ont donc une sémantique propre induisant des méthodes d'identification différentes. Les classes d'occupation du sol sont ainsi généralement établies à partir de données de télédétection alors que les classes d'utilisation du sol requièrent des données de type socioéconomique ou cadastral.

L'exploitation des données d'occupation du sol et d'utilisation du sol répond donc à des objectifs différents :

- les données relatives à l'occupation du sol permettent d'établir des cartes de couverture des sols à un instant précis (tributaire par exemple de la date d'acquisition de l'image satellite) pouvant par la suite être intégrées dans des modèles de type biophysique (modèles climatiques, modèles hydrologiques,...).

- En revanche, les données d'utilisation du sol, de par leurs caractéristiques attributaires, sont utilisées comme des outils d'aide à la décision afin d'élaborer des plans d'aménagement et de gestion du territoire.

Malgré ces différences sémantiques, les deux termes restent étroitement liés. La détermination de cartes d'occupation du sol à partir d'images satellites constitue ainsi la première étape pour établir un état des lieux d'un espace géographique. L'intégration de données exogènes de type vectoriel et alphanumérique à la couche occupation du sol autorise ensuite la création de classes d'utilisation du sol permettant d'affiner l'étude et la compréhension des dynamiques de la couverture terrestre. Les deux approches apparaissent donc complémentaires et indissociables pour une analyse pertinente des dynamiques spatiales d'un espace géographique.

2.7 Conclusion

La diversité des systèmes d'acquisition d'images ainsi que celle des plateformes spatiales et aéroportées va en augmentant au fur et à mesure que la télédétection progresse, avec une couverture de plus en plus étendue du domaine spectral et une grande variété de limites de résolutions spatiale. Les données de l'observation de la terre sont associées à cette dernière. Dans le chapitre qui suit, on s'intéresse à différentes méthodes de classification et de démixage du pixel.

CHAPITRE 3

TECHNIQUES DE DÉMIXAGE SPECTRAL

3.1 Introduction

Ce chapitre traite le problème du mélange spectral et expose quelques techniques de démixage spectral utilisé au chapitre 4 pour construire une carte d'occupation du sol à partir d'une image satellitaire. La section 3.2 est consacrée à l'explication des causes du phénomène du mélange spectral ainsi que les différents types de mélange qui en résultent. La modélisation de l'image satellitaire est présentée dans la section 3.3, où nous avons établi un modèle mathématique de l'image qui en prenant en considération le mélange linéaire, nous avons également cité les techniques développées à base de ce modèle pour surmonter le problème du mélange spectral dans la section 3.4.

3.2 Problème de la mixture spectrale

Le problème du mélange spectral se pose lorsque le domaine élémentaire relatif à un pixel donné comporte plusieurs matériaux, c'est à dire lorsqu'on atteint les limites de la résolution spatiale du capteur. Les pixels de mélange, autrement appelés « mixels » en imagerie numérique, peuvent apparaître dans deux cas [16]:

- lorsque le pixel se situe dans les limites d'un objet.
- lorsque les tailles des objets sont relativement petites par rapport à la résolution spatiale du capteur.

Le premier problème se produit lorsque l'image comprend des objets relativement petits auquel cas le mélange spectral est beaucoup plus probable. Le deuxième quant à lui intervient lorsque plusieurs matériaux sont en contact. Les pixels se trouvant aux bords des objets correspondent à un mélange de matériaux.

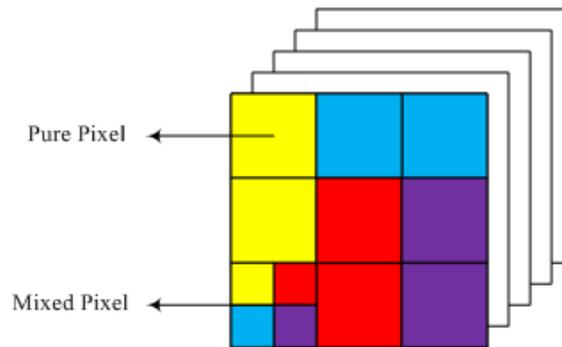
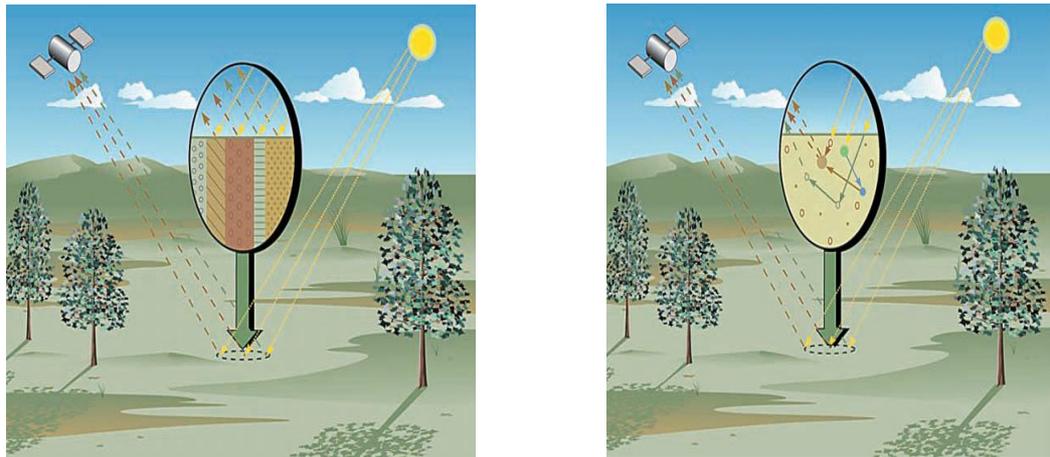


Figure 3.1 : Pixel pur et pixel mixte en imagerie satellitaire

Les techniques de classification classiques, basées sur les statistiques bayésiennes, supposent que les pixels sont purs et l'espace qu'il représente est homogène. Toutefois, à cause du problème des pixels mixtes, cette hypothèse n'est pas réaliste, spécialement dans les milieux arides ou semi-arides [17]. Ainsi, ce problème peut influencer d'une façon flagrante la fiabilité de la classification des images, et par conséquent, une représentation de l'image à travers un modèle approprié et optimisé s'avère indispensable.

Il existe quatre sortes de mélanges spectraux [18] [16] :

- **Mélange linéaire** : les matériaux dans un pixel sont optiquement séparables. Par conséquent il n'y a aucune dispersion entre les composants physiques. Le signal mélange est simplement la somme des réflexions spectrales des différents matériaux en présence, pondérées par les proportions de chaque matériau.
- **Mélange intime** : un mélange intime se produit quand les différents matériaux sont en contact intime dans un pixel, par exemple les grains minéraux dans le sol ou dans la roche. Le signal obtenu est une combinaison fortement non linéaire de toutes les réflexions spectrales. Cette combinaison dépend des propriétés optiques de chaque composant.
- **Mélange enduit** : l'enduit se produit quand un matériau couvre un autre matériau. Chaque enduit est une couche de dispersion/transmission dont l'épaisseur optique se détermine par rapport aux propriétés des matériaux et à la longueur d'onde. La plupart des enduits sont des mélanges non linéaires.
- **Mélange moléculaire** : ce phénomène se produit au niveau moléculaire, comme par exemple le mélange de deux matériaux liquides ou le mélange d'un matériau liquide et d'un matériau solide. Dans ce cas le mélange est également non linéaire.



(a) Modèle linéaire

(b) Modèle non-linéaire

Figure 3.2 : Modèles de mélange (a) linéaire (b) non-linéaire

3.3 Modélisation de l'image satellitaire

Dans ce paragraphe, nous présentons un système d'observation linéaire qui correspond à un cas particulier simplifié du cas général du mélange spectral. Ce cas se produit lorsque différents matériaux sont présents dans un pixel et qui sont optiquement séparables c'est-à-dire qu'il n'y a aucune dispersion entre les différents composants. Dans ce cas, la signature spectrale du mélange est la somme des signatures spectrales des différents matériaux présents dans ce pixel, pondérée avec les proportions de chaque matériau source comme l'illustre la figure ci dessous :

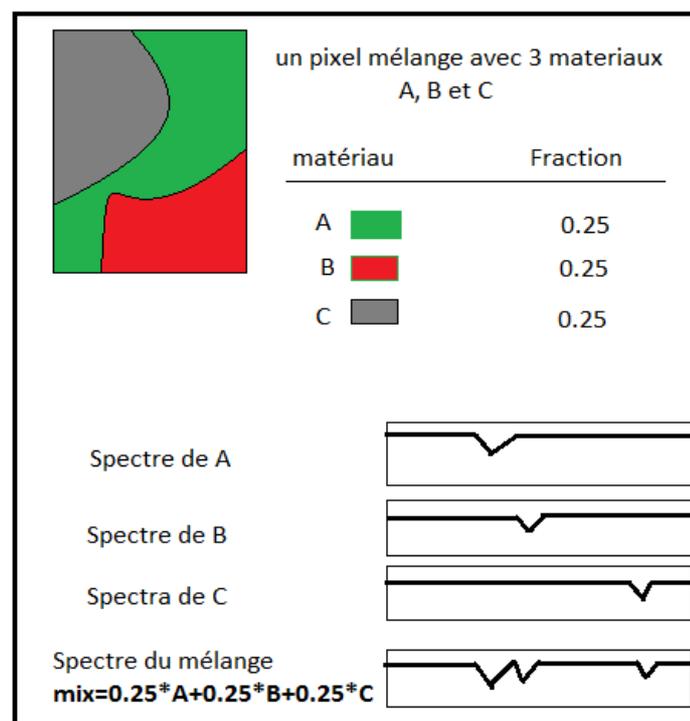


Figure 3.3 : Modélisation de mélange spectral

Du point de vue mathématique, la réflectance d'un pixel mixte x dans une bande spectrale j peut être exprimée par:

$$x_j = \sum_{i=1}^p m_{ij} \alpha_i + \varepsilon \quad (3.1)$$

Avec :

p : le nombre total des matériaux présents dans la scène.

m_{ij} : la réflectance de la signature spectrale du matériau i dans la bande j .

α_i : l'abondance de la source i .

ε : le bruit résiduel.

Généralement, ε est défini comme étant un bruit blanc gaussien additif considéré négligeable [19].

Le modèle linéaire permet d'écrire chaque pixel issu de l'image de télédétection comme étant un spectre défini par la somme pondérée des spectres des sources. Notons, que chacun de ces spectres est défini comme étant, la signature spectrale la plus représentative d'un matériau donné dans l'image. Ils sont appelés composantes spectrales (ou « Endmembers » pour les anglophones) et notés (EM). L'équation (3.1) s'écrit alors :

$$x = \sum_{i=1}^p m_i \alpha_i \quad (3.2)$$

Avec x le spectre d'un pixel mixte de l'image ou pixel observé et $(m_i)_{i=1,\dots,p}$ les EMs supposés être statistiquement indépendants, α_i la proportion de mélange du $i^{\text{ème}}$ EM dans le pixel observé. Ainsi, une image de N pixels, composée de P EMs et capturée sur L bandes peut s'écrire sous une forme matricielle comme suite :

$$X = \begin{bmatrix} x_{11} & \cdots & x_{1L} \\ \vdots & x_{ij} & \vdots \\ x_{N1} & \cdots & x_{NL} \end{bmatrix} = \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1p} \\ \vdots & \alpha_{ik} & \vdots \\ \alpha_{N1} & \cdots & \alpha_{Np} \end{bmatrix} \begin{bmatrix} m_{11} & \cdots & m_{1L} \\ \vdots & m_{kj} & \vdots \\ m_{p1} & \cdots & m_{pL} \end{bmatrix} \quad (3.3)$$

Avec :

x_{ij} est la valeur du $i^{\text{ème}}$ pixel dans la bande j .

α_{ik} est l'abondance du $k^{\text{ème}}$ EM dans le $i^{\text{ème}}$ pixel.

m_{kj} est la valeur du $k^{\text{ème}}$ EM dans la bande j .

N est le nombre des pixels dans la scène.

L est le nombre de bandes spectrales.

P est le nombre des EM.

Cette écriture matricielle, qui décrit le modèle de mélange linéaire d'une image satellitaire, n'aura un sens que lorsque les deux contraintes physiques suivantes sont satisfaites :

La *contrainte de positivité des abondances* :

$$\forall i, k: \alpha_{ik} \geq 0 \quad (3.4)$$

La *contrainte d'additivité des abondances* :

$$\sum_{j=1}^p \alpha_{jk} = 1 \quad (3.5)$$

Ayant défini le modèle d'observation, expliquant les dégradations subies par la présence des pixels mixtes dans la scène observée, nous nous intéressons désormais à la méthode dont on peut analyser cette scène.

Une propriété intéressante concerne la géométrie du problème, découlant de la forme du modèle et des contraintes. En effet, dans un sous-espace de \mathbb{R}^L , l'ensemble S tel que [29] :

$$S = \left\{ x \left| x = \sum_{i=1}^p m_i \alpha_i, \sum_{i=1}^p \alpha_i = 1, \alpha_i \geq 0, \forall i = 1 \dots p \right. \right\} \quad (3.6)$$

Définit un simplexe de dimension p-1. Ainsi, l'ensemble des observations non bruitées est contenu dans ce simplexe, comme l'illustre la figure (3.4). Les p sommets du simplexe correspondent aux différents spectres des endmembers $m_1 \dots, m_p$ présents dans l'image. Ainsi dans cette représentation, plus un pixel est proche d'un des sommets, plus il est pur. Le but du démixage est alors de retrouver les sommets de ce simplexe [20].

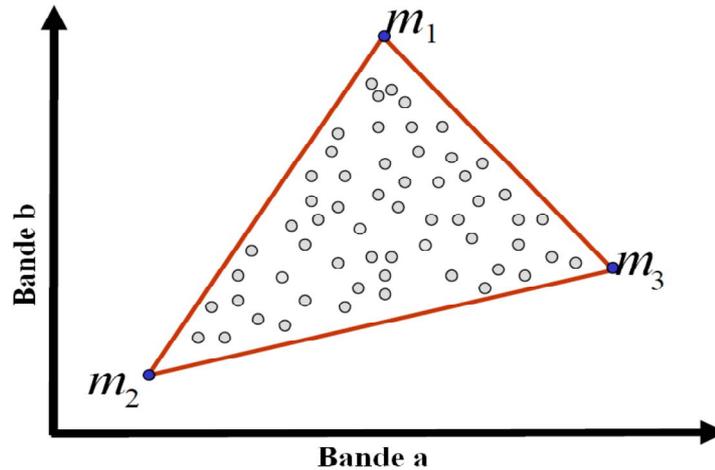


Figure 3.4 : Représentation en deux bandes des observations non bruitées (points gris) contenues dans le simplexe (en rouge).

3.4 Les techniques de démixage spectral

De nombreuses méthodes de démixage spectral, basées sur le modèle de mélange linéaire, ont été proposées dans la littérature. Nous citons en l'occurrence, les méthodes Multiple Endmember Spectral Mixture Analysis (MESMA) [21], Spectral Mixture Analysis (SMA) [22], Derivative Spectral Unmixing (DSU) [23], Variable Multiple Endmember Spectral Mixture Analysis (VMESMA) [24], Singular Value Decomposition (SVD) [25], Subspace Projection (SP) [26], Maximum Likelihood (ML) [17]. La plupart des algorithmes d'estimation adaptés au modèle de mélange linéaire (MML) commencent par estimer les composantes spectrales du modèle à l'aide d'algorithmes d'extraction comme l'algorithme Nfinder (N-FINDR) ou l'algorithme Vertex Component Analysis (VCA). Dans une seconde étape, les algorithmes estiment les coefficients du mélange (abondances) à l'aide d'une procédure qualifiée de démelange linéaire. L'inconvénient majeur de ces méthodes réside dans leur dépendance à la bibliothèque spectrale qui est, dans la pratique, difficile à obtenir [17]. Pour remédier à cette contrainte, une autre approche plus récente a été proposée pour le démelange linéaire spectral est la séparation aveugle des sources (SAS). A l'aide des méthodes SAS, on peut espérer démelanger chaque pixel, et aboutir à l'identification de la signature spectrale de chaque composant pur, permettant aussi la quantification constituant la surface et la cartographie de leur distribution spatiale [27]. La SAS est un problème générique de traitement de signaux, d'images ou de données. Elle consiste à estimer un ensemble de signaux observés qui sont des mélanges de ces signaux source [27]. L'application de l'analyse en composantes indépendants pour le démixage spectral est très connue dans les traitements de séparation aveugle de sources. Ainsi, son applicabilité à l'extraction des EM semble naturelle et

justifiée. Ces méthodes n'exigent pas des informations a priori et travaillent à partir de l'unique information portée par l'image. Toutefois, ces méthodes présentent aussi certains inconvénients principalement en termes de sensibilité aux effets de changement d'illumination, causés essentiellement par les effets de l'ombrage [17].

3.4.1 Les techniques de mise en correspondance spectrale

Les techniques de mise en correspondance spectrale s'emploient normalement dans le cas où une comparaison entre deux spectres est nécessaire. Chaque pixel est un vecteur L dimensionnel, où L est le nombre de canaux spectraux. Par ces techniques, les informations spatiales ne sont généralement pas considérées, car chaque pixel vectoriel est la base du traitement [16]. Ces techniques ont besoin des connaissances a priori sur les objets ou matériaux. Pour cela une étape d'estimation, du nombre et des spectres des signatures de référence (EM) qui sont présents dans l'image, doit répondre aux besoins ces techniques. L'idée fondamentale dans les techniques de mise en correspondance spectrale est de définir certaines mesures de similarité entre un vecteur de référence et un vecteur à classer. L'estimation des valeurs de similarité pour une classe de matériaux peut être considérée comme la projection d'un espace à L -dimensions sur un espace monodimensionnel [17]. Pour un vecteur de référence \vec{r} et un pixel inconnu \vec{p} nous pouvons formuler la projection de similarité comme suit :

$$S = f(\vec{r}, \vec{p}) \quad (3.7)$$

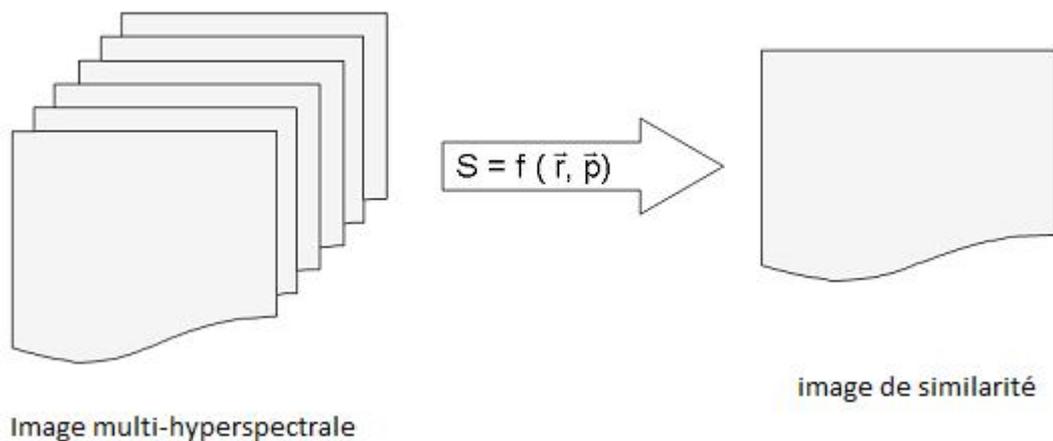


Figure 3.5: La projection de similarité

Il existe différentes mesures de similarité, elles peuvent être regroupées deux classes principales [16]:

- Les mesures probabilistes.
- Les mesures déterministes.

Les mesures probabilistes s'appuient sur la théorie de l'information en utilisant les caractéristiques statistiques des données afin d'analyser les propriétés spectrales. Les mesures probabilistes résultant de ces méthodes incluent la mesure d'information spectrale, le codage binaire et la mesure spectrale markovienne.

Les mesures déterministes définissent les critères spectraux basés sur les mesures physiques de similarité comme la valeur spectrale, la distance, l'angle et la corrélation spectrale.

3.4.1.1 Similarité Angle Spectral (Spectral Angle Mapper SAM)

La SAM est une approche de classification basée sur un concept physique [3]. Dans cette approche, on utilise toutes les bandes spectrales. Elle détermine par calcul de l'angle θ (en radian), la similarité entre un spectre de référence et un spectre de l'image (figure 3.6). La génération des signatures spectrales de référence peut être réalisée à partir de l'image ou en utilisant des spectres de terrain. Cet angle spectral est calculé à partir de l'équation suivante [26] :

$$\theta = \cos^{-1}\left(\frac{\vec{p} \cdot \vec{r}}{\|\vec{p}\| \cdot \|\vec{r}\|}\right) \quad (3.8)$$

Où

\vec{r} : est le vecteur du spectre de référence (prototype)

\vec{p} : est le vecteur du spectre test (pixel)

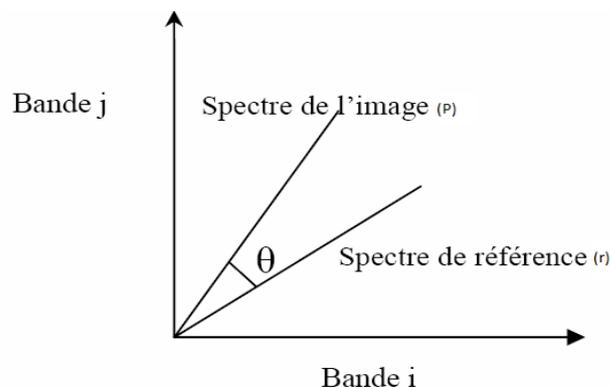


Figure 3.6: Angle spectral entre le spectre de référence et le spectre image dans un espace bidimensionnel.

L'approche considère les valeurs du pixel comme un vecteur dans un espace ayant une dimension égale au nombre de bandes. C'est une approche rigoureuse non sensible à l'albédo à condition d'utiliser des données calibrées [3]. L'affectation de chaque pixel de l'image à une classe donnée se base sur la mesure de l'angle entre le vecteur du spectre de référence et chaque vecteur de l'image dans l'espace à L dimensions [26].

L'exécution de l'approche du SAM permet d'obtenir une image d'angle θ pour chaque spectre de référence. À partir des images d'angle θ , nous réalisons un seuillage afin d'attribuer à chaque pixel le thème qui y possède la valeur la plus faible de θ : plus l'écart angulaire est petit, plus la similarité est importante. Ce concept de classification est assez intéressant pour la cartographie de l'état de surface et des ressources naturelles (sols, végétation) [6]. Les méthodes conventionnelles, telles qu'Isodata et la distance minimum, utilisent la distance euclidienne simple comme critère de similarité [16]. Si l'on préfère disposer de valeurs normalisées, on peut utiliser le cosinus de l'angle ce qui permet en outre de s'affranchir du calcul de l'arc-cosinus.

Zouhaier Ben Rabah propose une alternative afin d'obtenir des valeurs de similarité comprises entre 0 et 1 [17]:

$$\hat{\theta} = 2\alpha/\pi \quad (3.9)$$

3.4.1.2 Similarité Distance Spectrale (SDS)

Dans le traitement des signaux, différentes métriques sont employées pour mesurer la séparation ou la proximité des vecteurs de données. Le choix de la métrique précise le type de norme employée, par exemple, la distance de City block, la distance euclidienne et la distance de Tchebychev sont quelques métriques correspondant aux normes l_1 , l_2 , et l_∞ , [16]. La distance euclidienne est appliquée fréquemment comme une mesure de similarité pour l'image satellitaire [16]. Comme dans le cas de l'angle spectral, la distance peut s'imaginer dans l'espace du phénomène comme illustrée dans la figure 3.7.

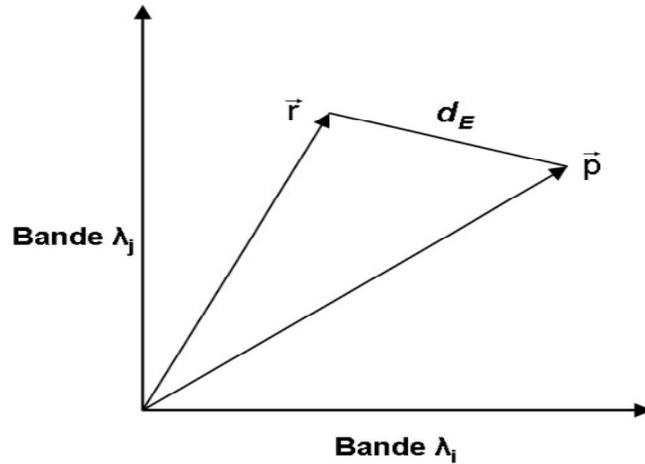


Figure 3.7: La similarité spectrale par la distance

L'équation générale pour calculer la distance euclidienne est :

$$d_E = \sqrt{\sum_{i=1}^n (r_i - p_i)^2} \quad (3.10)$$

Où

\vec{r} : est le vecteur du spectre de référence (prototype).

\vec{p} : est le vecteur du spectre test (pixel).

Là encore, l'identification des pixels correspondant à la référence se fait par la prise de décision sur les valeurs de similarité. De cette manière, si le spectre du pixel est similaire au pixel de référence, la distance doit être proche de zéro. Par contre, il n'y a pas de maximum connu pour les cas de faibles similarités. C'est pourquoi, nous normalisons les valeurs de distance par [16]:

$$\widehat{d}_e = \frac{d_e - m}{M - m} \quad (3.11)$$

Où m et M sont les valeurs de distance minimum et maximum. Par cette transformation linéaire, le maximum de similarité donne 0 et le minimum de similarité donne 1.

3.4.1.3 Similarité Corrélation Spectrale (SCS)

La corrélation statistique de Pearson peut aussi être employée comme une mesure de similarité. Elle montre comment deux vecteurs (celui de référence et celui du pixel inconnu) sont corrélés.

Pour deux vecteurs \vec{r} et \vec{p} , nous pouvons la calculer par :

$$\rho = \frac{\langle \vec{r}, \vec{p} \rangle - L \mu_r \mu_p}{(L - 1) \sigma_r \sigma_p} \quad (3.12)$$

Avec :

\langle , \rangle : Signifie le produit scalaire de deux vecteurs

μ : La moyenne

σ : L'écart-type.

\vec{r} : Vecteur de référence

\vec{p} : Vecteur inconnu

Les valeurs de corrélation sont dans l'intervalle $[-1,1]$. Pour un pixel similaire à la référence, la corrélation est égale à 1. Pour disposer de valeurs comprises entre 0 et 1 comme pour les mesures précédentes, nous ignorons les valeurs négatives. Cette mesure est capable de séparer les classes principales, car il y a une relation assez forte entre les vecteurs spectraux des différents matériaux similaires au sein d'une classe, comme par exemple les différents types de végétation [16].

3.4.1.4 Similarité Valeur Spectrale (SVS)

La similarité de valeur spectrale est la combinaison de deux mesures : la corrélation et la distance Euclidienne. Elle peut être formulée comme :

$$v = \sqrt{\widehat{d}_e^2 + (1 - \rho)^2} \quad (3.13)$$

Où \widehat{d}_e et ρ s'obtiennent par les équations (3.11 et 3.12). Des vecteurs identiques ont des grandeurs et des directions identiques. Pour un spectre considéré comme un vecteur, la norme de ce vecteur correspond à la réflexion spectrale et sa direction correspond à la forme spectrale (y compris toutes les absorptions et les émissions par les processus atmosphériques). Dans la formulation du SVS, la distance Euclidienne mesure principalement la différence d'intensité entre deux vecteurs, alors que la corrélation compare les formes des deux spectres. Ainsi, la valeur de la similarité spectrale combine la similarité de l'intensité et de la forme [16]. Si nous avons mis toutes les valeurs négatives de corrélation à zéro, elle serait comprise entre 0 et $\sqrt{2}$. Les faibles valeurs de SVS révèlent des spectres similaires.

3.4.2 Réduction de dimension

La taille des données peut être mesurée selon deux dimensions, le nombre de variables et le nombre d'exemples. Ces deux dimensions peuvent prendre des valeurs très élevées, ce qui peut poser un problème lors de l'exploration et l'analyse de ces données. Pour cela, il est fondamental de mettre en place des outils de traitement de données permettant une meilleure compréhension de la valeur des connaissances disponibles dans ces données. La

réduction des dimensions est l'une des plus vieilles approches permettant d'apporter des éléments de réponse à ce problème. Son objectif est de sélectionner ou d'extraire un sous-ensemble optimal de caractéristiques pertinentes pour un critère fixé auparavant. La sélection de ce sous-ensemble de caractéristiques permet d'éliminer les informations non pertinentes et redondantes selon le critère utilisé.

3.4.2.1 Nécessité de réduire le nombre de bandes

La classification d'images multidimensionnelles se heurte, lorsque le nombre de bandes spectrales est important, au problème connu sous le nom de malédiction de la dimension ou phénomène de Hughes. En effet, à nombre de pixels fixe, l'ajout d'une bande spectrale s'accompagne par un accroissement du nombre de paramètres du modèle et donc inévitablement une baisse de précision de leur estimation entraînant une dégradation de la qualité des décisions prises. L'espace est de plus en plus vide avec l'augmentation de la dimension [28].

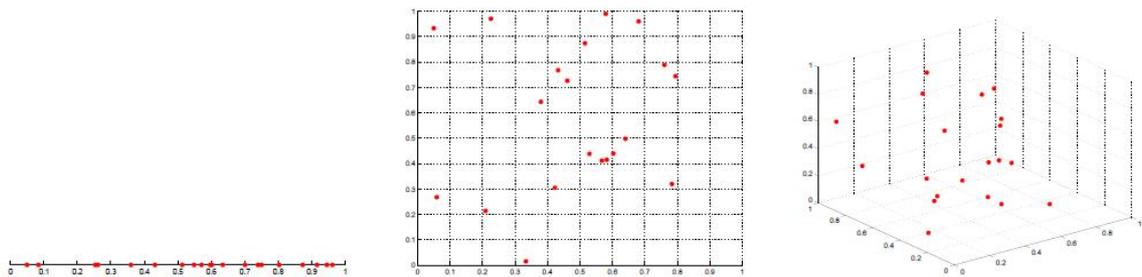


Figure 3.8: Illustration du problème de la malédiction de dimension.

La figure ci dessus illustre ce problème de gauche à droite, nous avons tiré suivant une loi uniforme 20 échantillons de dimension respectivement 1, 2 et 3. En augmentant la dimension, à nombre d'échantillons fixe, l'espace présente des échantillons de plus en plus clairsemés.

Plusieurs techniques de réduction de dimensionnalité ont été proposées en imagerie de télédétection pour contourner ce problème. Le but est de rechercher une projection vers un espace de plus faible dimension en optimisant un critère donné. Comme exemples les techniques des projections linéaires, on peut évoquer l'Analyse en Composantes Principales (ACP), l'Analyse Factorielle (AF), l'Analyse en Composantes Indépendantes (ACI) et l'Analyse Discriminante de Fisher (ADF). Pour les techniques non linéaires, on peut citer les deux méthodes de poursuite de projections

3.4.2.2 L'analyse en composantes principales(ACP)

Les images d'une même scène enregistrées suivant les différentes bandes spectrales du capteur sont hautement corrélées. Compte tenu de l'abondance d'informations à traiter, le but de l'ACP est de condenser les données originelles en de nouveaux groupements de façon à ce qu'ils ne présentent pas de corrélation entre eux et soient ordonnés en terme de pourcentage de variance apportée par chaque composante [29]. Ainsi la première composante principale contient les informations relatives à la variance maximale, la deuxième contient les informations relatives à la variance suivante. Le processus est répété jusqu'à l'obtention de la n^{ième} et dernière composante principale [29]:

Ayant un ensemble de vecteurs X_i , $i = 1, \dots, N$, de dimension L , la méthode consiste à chercher les axes de projection orthogonaux suivant lesquels la variance est maximisée. L'approximation optimale, au sens de l'erreur quadratique moyenne, d'un vecteur X_i par un vecteur \hat{y}_i de dimension ($p < L$) est donnée par [28] :

$$\hat{y}_i = W_p^t (X_i - \mu) \quad (3.14)$$

Où μ est la moyenne des X_i et W_p est la matrice de projection composée des p premiers vecteurs propres de la matrice de covariance des données ($\sum x$) correspondant aux p plus grandes valeurs propres données dans un ordre descendant $(\lambda_i)_{i=1, \dots, p}$.

L'erreur quadratique de l'approximation est donnée par la somme des valeurs propres écartées :

$$e^2 = \sum_{i=p+1}^L \lambda_i \quad (3.15)$$

Le choix de p peut être basé sur l'équation (3.15), ou d'une manière équivalente sur le choix d'un seuil s entre 0 et 1 tel que :

$$\frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^L \lambda_i} \geq s \quad (3.16)$$

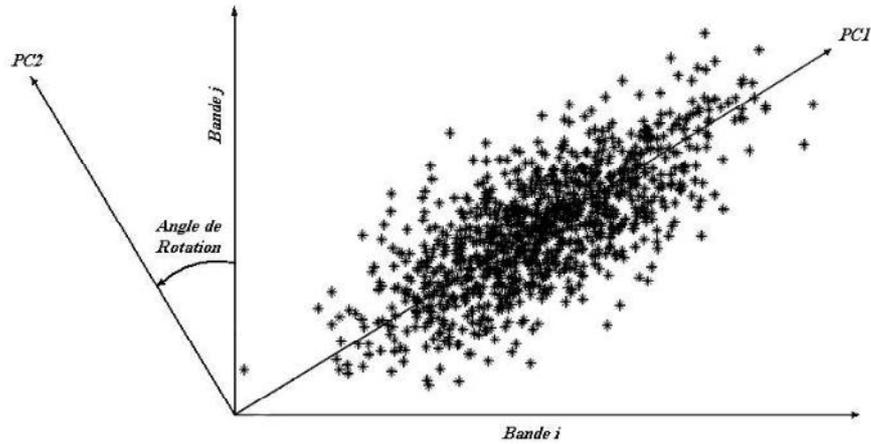


Figure 3.9 : La rotation des composantes dans un espace
L'algorithme de l'ACP se déroule selon les étapes décrites ci-dessous :

1- Calcul les matrices de covariance et de corrélation de l'image

Ce sont des matrices carrées dont la dimension est égale au nombre des canaux spectraux de l'image.

Soient X_j $j=1,\dots,L$ les variables représentant les N pixels en niveaux de gris des L images obtenues par les capteurs spectraux.

$$X^j = [x_1^j, \dots, x_i^j, \dots, x_N^j]$$

La matrice des données est:

$$X = \begin{pmatrix} x_{11} & \dots & x_{1j} & \dots & x_{1L} \\ \vdots & & \vdots & & \vdots \\ x_{i1} & \dots & x_{ij} & \dots & x_{iL} \\ \vdots & & \vdots & & \vdots \\ x_{N1} & \dots & x_{Nj} & \dots & x_{NL} \end{pmatrix} \quad (3.17)$$

Où L est le nombre de bandes spectrales et N le nombre des pixels.

Afin de calculer la matrice de covariance ($\sum x$) il faut commencer par l'estimation du vecteur moyen des données :

$$\mu_j = \frac{1}{N} \sum_{i=1}^N X^j \quad (3.18)$$

où μ_j est la moyenne des pixels obtenue pour la bande j , $j=1,\dots,L$.

Ces moyennes servent à calculer les covariances et la corrélation entre deux variables. La covariance entre deux variables X_i et X_j ($i,j=1,\dots,L$) est donnée par :

$$\sigma_{ij} = \frac{1}{N} \sum_{k=1}^N [(X_i^k - \mu_i) \cdot (X_j^k - \mu_j)^t] \quad (3.19)$$

et la matrice Σ_x correspond à :

$$\Sigma_x = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1L} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2L} \\ \vdots & \vdots & \sigma_{ij} & \vdots \\ \sigma_{L1} & \sigma_{L2} & \cdots & \sigma_{LL} \end{bmatrix} \quad (3.20)$$

Les éléments de Σ_x représentent la corrélation entre deux bandes spectrales de données. Les valeurs les plus grandes signifient que la corrélation est forte et les valeurs proches de zéro signifient qu'il y a une absence de corrélation entre les canaux. La matrice de corrélation, R peut mieux introduire la corrélation intra-bandes d'une manière unique :

$$R = \begin{pmatrix} \rho_{11} & \rho_{12} & \cdots & \rho_{1L} \\ \rho_{21} & \rho_{22} & \cdots & \rho_{2L} \\ \vdots & \vdots & \rho_{ij} & \vdots \\ \rho_{L1} & \rho_{L2} & \cdots & \rho_{LL} \end{pmatrix} \quad (3.21)$$

Où

$$\rho_{ij} = \frac{\sigma_{ij}}{\sqrt{\sigma_{ii} \cdot \sigma_{jj}}} \quad (3.22)$$

Les valeurs ρ_{ij} sont entre $[-1,1]$. Une valeur proche de 1 signifie qu'il existe une corrélation forte entre les deux canaux. Au contraire -1 signifie qu'il y a une corrélation négative forte. Le zéro indique qu'il n'existe pas une corrélation significative entre les canaux.

2- Calcul des valeurs propres et des vecteurs propres de la matrice de covariance

Les polygones caractéristiques de la matrice de covariance nous permettent le calcul des valeurs propre λ_i , ce sont les valeurs qui vérifient:

$$\text{Det}(R - \lambda I_L) = 0 \quad (3.23)$$

On obtient L valeurs propres $\lambda_1, \dots, \lambda_L$, associées à L vecteurs propres V_1, \dots, V_L telles que :

$$R * V_i = \lambda_i * V_i \quad \text{avec } i = 1, \dots, L \quad (3.24)$$

3- Calcul des composantes principales de l'image

le nombre des composantes est au plus au moins égal à celui des canaux spectraux .A partir des vecteurs propre de la matrice de corrélation on peut obtenir les composantes principales .

3.4.3 Méthodes d'extraction des composantes spectrales (Endmembers)

Le point clé du démixage spectral linéaire réside dans la recherche des signatures spectrales pures. Ces dernières peuvent être soit extraites des bibliothèques spectrales (obtenues par des mesures en laboratoire), soit obtenues à partir de l'image observée. Il est à noter que, tout en étant conscient du risque de possibles différences avec les données observées (dus aux conditions d'acquisition), l'utilisation des bibliothèques spectrales s'avère très avantageuse pour le démixage spectral lorsqu'elles sont à disposition [20].

La connaissance du nombre de composants purs présents dans l'image est généralement obligatoire pour extraire les endmembers. Ce nombre peut être estimé en effectuant une ACP sur les vecteurs d'observations de l'image [30]. Considérant les valeurs propres triées λ_i ($i = 1 \dots L$) de la matrice de covariance des observations, la quantité η définie par

$$\eta = \frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^L \lambda_i} \quad (3.25)$$

Où $p < L$ peut être utilisée pour rechercher la dimension du sous-espace contenant l'information pertinente liée aux données. Cette dimension est par exemple déterminée en fixant un seuil de qualité choisi tel que η soit suffisamment proche de 1 ($\eta = 90\%$ ou $\eta=99\%$). Comme la dimension du simplexe est par définition égale à $R + 1$, on déduit alors facilement le nombre d'endmembers $R = P+1$.

Ce nombre des endmembers R peut également être estimé en utilisant par exemple la technique Virtuel Dimensionality (VD). Olivier Eches [20] propose deux algorithmes (HFC) et Noise-Whitened HFC (NWHFC). Le premier se base sur la comparaison des valeurs propre triées par ordre décroissant et prise deux à deux de la matrice de corrélation avec celle de covariance. Si la valeur propre de la matrice de corrélation est supérieure à celle de la matrice de covariance et que cette dernière est supérieure à la variance du bruit alors on est en présence d'un endmember qui contribue à la valeur propre de corrélation en plus du bruit. Thématiquement, ceci signifie qu'on est en présence d'une nouvelle classe. Par contre si les deux valeurs propres sont égales aux variances du bruit, ceci implique l'absence de l'endmember. Le deuxième algorithme est similaire au premier sauf qu'il traite le bruit avant d'appliquer le HFC [20].

Parmi les méthodes d'extraction des signatures spectrales basées sur le modèle linéaire on peut citer les célèbres algorithmes N-FINDR de Winter et Pixel Purity Index (PPI) de Boardman [20]. Ces algorithmes cherchent à retrouver le simplexe d'intérêt à partir de projections sur des espaces appropriés (PPI), ou bien en calculant itérativement le simplexe de plus grand volume (N-FINDR). Néanmoins, le PPI nécessite un nombre élevé

d'itérations alors que le N-FINDR dépend fortement des pixels initiaux sélectionnés pour le calcul du volume du premier simplexe [20]. Un autre algorithme, appelé Vertex Component Analysis (VCA) [30], exploite la projection dans des sous-espaces orthogonaux afin de retrouver directement les endmembers. Ces trois algorithmes se basent sur l'hypothèse de l'existence d'au moins un pixel pur dans l'image. D'autres approches sont possibles comme la méthode Automated Morphological Endmember Extraction (AMEE) intégrant des informations spatiales par l'utilisation d'opérateurs morphologiques [17], ou bien la méthode Orthogonal Subspace Projection (OSP) [26] qui suit le même principe que la méthode VCA sans toutefois faire l'hypothèse que les endmembers soient les sommets d'un simplexe.

3.4.4 Le démixage par la séparation aveugle des sources

L'approche dite de séparation aveugle des sources consiste à restaurer des signaux sources S_j à partir de signaux mélanges x_i (appelés aussi observation). De manière générale ces observations peuvent provenir des capteurs tels que des microphones, des antennes radiofréquences, des capteurs CCD,... Le mélange entre les signaux sources est dû à la propagation de ces derniers jusqu'aux capteurs. L'objectif est donc de construire un système capable de fournir des sorties y_i égales aux signaux S_j [27].

La configuration générale de la séparation de sources est représentée par la figure suivante :

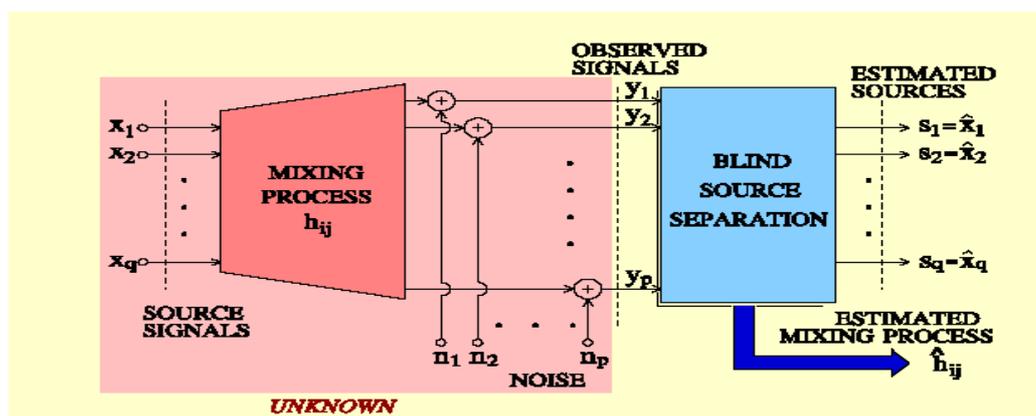


Figure.3.10 : Séparation aveugle des sources [17]

Le mot « aveugle » provient du fait que les sources et les paramètres du mélange sont inconnus.

La SAS possède plusieurs degrés de difficulté ; en effet plusieurs paramètres sont à prendre en considération. Le premier paramètre est le nombre m d'observations par rapport au nombre L de sources. Intuitivement, on conçoit aisément que le cas (sur)déterminé $m=L$

($m > L$) est plus simple à résoudre que le cas sous-déterminé $m < L$, car les observations fournissent une information plus riche dans le cas (sur)déterminé [27].

Le deuxième paramètre concerne le type de mélange. Le cas le plus étudié à ce jour est le mélange linéaire [17]:

$$X = A.S \quad (3.26)$$

où :

$S = (s_1, s_2, \dots, s_L)^T$ est le vecteur des signaux aléatoires statistiquement indépendants appelés sources, ayant des distributions de probabilité inconnue. Ce sont en fait les signaux indépendants émis par les L sources et $X = (x_1, x_2, \dots, x_m)^T$ est le vecteur des mesures apportées par m capteurs sur les combinaisons linéaires des n signaux sources.

Le but de la SAS est donc de retrouver la matrice de séparation W tel que :

$$S = W.X \quad (3.27)$$

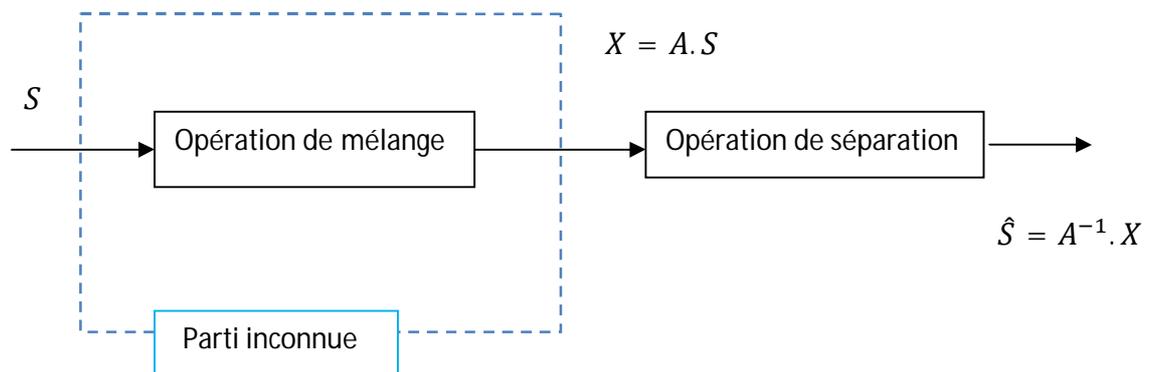


Figure 3.11 : Schéma général de la séparation aveugle des sources

La figure (3.11) montre le schéma général de la SAS où :

X est le vecteur des signaux mesurés sous forme d'un mélange linéaire (c'est la seule information disponible),

S est le vecteur des signaux sources originaux,

\hat{S} est le vecteur des signaux sources estimés à l'aide d'un algorithme de séparation aveugle de sources

et A est la matrice de mélange inconnu tel que :

$W \approx A^{-1}$, et ce à un facteur près qu'il faudra essayer de trouver [5]. En combinant les équations (3.25) et (3.26), nous obtenons la matrice du système global de séparation aveugle de sources, d'ordre $m \times L$ et notée par C , tel que :

$$C = A.W \quad (3.28)$$

La figure (3.12), représente le schéma global du système de séparation aveugle de sources. Nous remarquons que, dans un cas idéal où \hat{S} serait égale à S , la matrice C trouvée serait égale à la matrice identité [5].

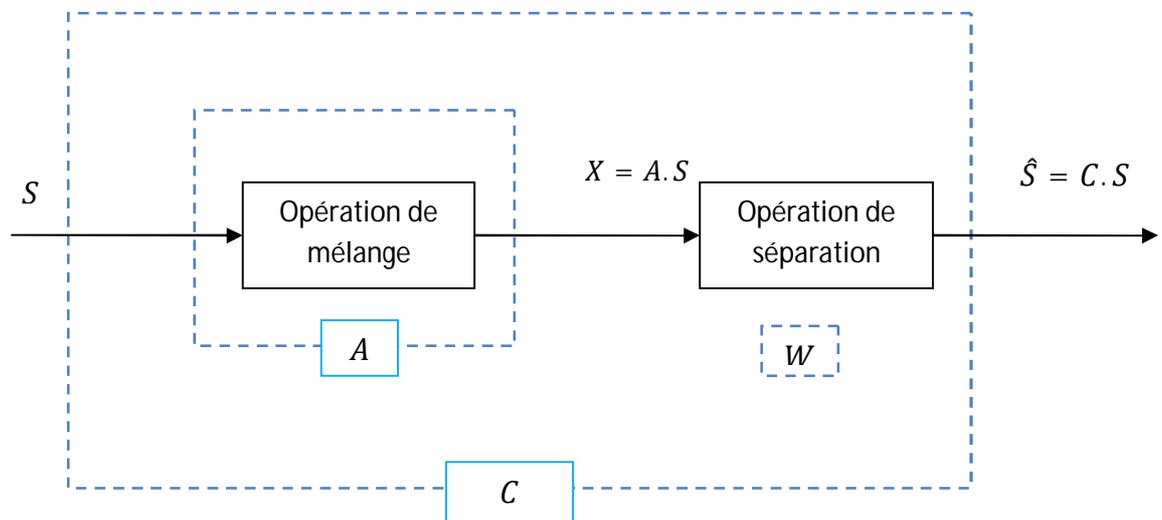


Figure 3.12: Schéma global

3.4.4.1 Analyse en composantes indépendantes

L'ACI est un outil d'analyse, des données multidimensionnelles, qui se base sur les statistiques d'ordre supérieur et l'hypothèse de l'indépendance statistique des sources supposées inconnues. L'objectif de l'ACI est de trouver une nouvelle base de représentation dans laquelle les projections des observations sur cette base fournissent des composantes indépendantes. Concrètement, ce processus se traduit par la séparation aveugle de sources naturellement indépendantes à partir des signaux observés, en se basant uniquement sur leur mélange [17].

3.4.4.1.1 Définition et principes de l'ACI

Si nous considérons un système de capteurs capable d'enregistrer la combinaison linéaire de certaines sources ($S_i, i=1, \dots, p$) à n instants particuliers, le modèle proposé par l'ACI est [31] :

$$X = A.S + N \quad (3.29)$$

Sous forme matricielle, S regroupe des vecteurs décrivant les sources indépendantes originales, A est une matrice de fractions de combinaison du mélange, N est la matrice de bruits et enfin, X regroupe les vecteurs concernant les observations. Ce modèle est un modèle général, c'est-à-dire qu'il décrit comment les données observées, ont été générées par un procédé de mélange des composantes S . Le but de l'ACI est donc, d'estimer la matrice \hat{S} , par une transformation linéaire telle que :

$$\hat{S} = W.X \quad (3.30)$$

Pour ce faire, il faut d'abord trouver la matrice de séparation W (se formant comme $W = A^{-1}$) qui s'écrit :

$$W = \begin{pmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \vdots & \vdots & w_{ij} & \vdots \\ w_{p1} & w_{p2} & \dots & w_{pn} \end{pmatrix} \quad (3.31)$$

L'ACI nécessite la vérification de conditions fondamentales. Pour l'appliquer efficacement, les conditions suivantes doivent être considérées [16]:

1. Tous les éléments de la matrice S doivent être statistiquement et mutuellement indépendants. Mathématiquement, pour les variables s_i , l'indépendance statistique peut être définie comme [16]:

$$f(s_1, s_2, \dots, s_p) = f_1(s_1) \cdot f_2(s_2) \dots f_p(s_p) \quad (3.32)$$

où $f_i(s_i)$ est la fonction de densité marginale.

2. Il existe au maximum une source Gaussienne (avec une distribution normale).

3. Le nombre de sources doit être inférieur ou égal à la dimension des données ($p \leq n$).

Critères de séparation

Dans la littérature, plusieurs critères de séparation fondés sur les mesures de dépendance ont été définis [17]:

1 Critères de séparation basés sur la corrélation non linéaire

Ces critères sont basés sur l'utilisation du maximum de la corrélation non linéaire appelée F défini par :

$$P_F = \max[\text{corr}(f_1(X_1), f_2(X_2))] = \frac{\max[\text{cov}(f_1(X_1), f_2(X_2))]}{\sqrt{\text{var}(f_1(X_1)) \cdot \text{var}(f_2(X_2))}} \quad (3.33)$$

où : X_1 et X_2 sont des variables aléatoires réelles.

Si $P_F = 0$, alors X_1 et X_2 sont indépendantes

2 Critères basés sur des mesures quadratiques

Ces critères prennent en considération la comparaison de la densité conjointe avec le produit des densités marginales, parmi ces mesures la divergence de Kullback-Leibler et l'information mutuelle

** Divergence de Kullback-Leibler*

La divergence de Kullback-Leibler permet de mesurer l'écart qui existe entre la densité conjointe et le produit des densités marginales. Cet écart est la mesure d'indépendance statistique [5].

Notons que les composantes de la variable aléatoire $X = (x_1, x_2, \dots, x_m)^T$ sont dites mutuellement indépendantes statistiquement si et seulement si :

$$P(X) = \prod_{i=1}^m P(x_i) \quad (3.34)$$

où $P(X)$ est la distribution de X et $\prod_{i=1}^m P(x_i)$ est le produit de ses distributions marginales.

Soient $f(x)$ et $g(x)$ deux densités de probabilités des deux composantes de la variable aléatoire X . Ainsi, la divergence de Kullback-Leibler est définie par :

$$D_{fg} = \int_{-\infty}^{+\infty} f(x) \cdot \log\left(\frac{f(x)}{g(x)}\right) dx \quad (3.35)$$

Il est clair que la divergence de Kullback-Leibler ne s'annule que lorsque les deux composantes de X sont statistiquement indépendantes [17].

**Information mutuelle*

L'information mutuelle peut être considérée comme la distance de Kullback-Leibler entre les densités conjointes et les densités marginales. Ainsi, l'information mutuelle de la variable aléatoire X, notée I(X), peut être exprimée comme étant la divergence de Kullback-Leibler entre sa distribution P(X) et le produit de ses distributions marginales P(x_i) [4]:

$$I(X) = D(P(X) | \prod_{i=1}^m P(x_i)) \quad (3.36)$$

En utilisant le concept de l'entropie différentielle. On peut reformuler l'information mutuelle I(X) comme suit :

$$I(X) = I(x_1, x_2, \dots, x_m) = \sum_{i=1}^m H(x_i) - H(X) \quad (3.37)$$

où les H(x_i) sont les entropies marginales des composantes x_i et H(X) l'entropie conjointe.

3 Critères basés sur le caractère Gaussien des variables

Ces critères sont basés sur le principe que moins les variables sont gaussiennes plus elles sont indépendantes, parmi ces critères il y a ceux basés sur le kurtosis ou la néguentropie [17].

3.4.4.1.2 Application de l'ACI en imagerie satellitaire

L'utilisation de l'ACI en imagerie de télédétection trouve son intérêt du fait de la similarité de son modèle avec le modèle de mélange linéaire. En effet, les correspondances suivantes peuvent être établies [20]:

Matrice de mélange A	↔	matrice des signatures spectrales	m
Vecteur source S	↔	vecteur d'abondance	α

Ces correspondances ont rendu l'utilisation de l'ICA populaire en imagerie de télédétection pour trois applications majeures :

➤ **Le démixage des données:** il consiste à estimer les signatures spectrales des objets et la proportion de leur occupation à chaque pixel (leur abondance) en utilisant uniquement les données observées (les pixels mélangés). L'ICA sépare autant de composantes indépendantes (Cis) qu'il y a d'objets dans la scène. Chaque composante est alors considérée comme étant l'estimation de la carte d'abondance d'un objet donné. Même si l'utilisation d'ICA à cette fin est attrayante, elle suscite quelques discussions et sa capacité à séparer les données hyperspectrales est remise en cause, du fait que le critère d'indépendance des sources ne soit justifié physiquement dans ce cas. Des méthodes plus adaptées aux données ont été proposées pour séparer aux mieux les données hyperspectrales [30].

➤ **La réduction des données:** elle cherche à favoriser les statistiques d'ordre supérieur pour l'extraction de données. En effet, les cibles de petite taille ou qui sont peu présentes dans la scène ne sont pas correctement caractérisées par les statistiques du second ordre. Ceci est dû au fait que les observations de ces cibles ne sont pas en assez grand nombre pour constituer une statistique fiable.

➤ **L'extraction des endmembers :** L'extraction des EM à partir des CI retenues est réalisée en se basant sur une technique simple à implémenter. L'idée proposée par J. Wang et C. Chang [31] consiste à sélectionner à partir de chaque CI retenue le pixel dont la radiométrie est maximale.

$$Z_n^i = \max(CI_i) \quad (3.38)$$

Avec Z_n^i est la valeur de niveau de gris du $n^{\text{ième}}$ pixel de la $i^{\text{ème}}$ CI.

La signature spectrale du pixel sélectionné est supposée être une signature spectrale pure

3.4.4.1.3 Implémentation de l'ACI

La majorité des algorithmes qui ont été utilisés pour la séparation de sources se basent sur l'analyse en composantes indépendantes. L'objectif de ces algorithmes est d'utiliser les valeurs radiométriques des pixels présentant des informations composites et qui reflètent des informations relatives à des objets hétérogènes existant dans la scène. Ces algorithmes opèrent dans le but de dissocier les objets pertinents de leur environnement afin de déterminer les différents types de matériaux au sol. Nous présentons dans ce qui suit les trois algorithmes les plus utilisés pour l'ACI [17].

a. *FAST – ICA* (Fast Independent component Analysis)

Cet algorithme est conçu pour extraire les composantes indépendantes à partir des signaux multidimensionnels et complexes en entrée. Il essaie de maximiser la non Gaussianité comme une mesure de l'indépendance statistique. La non Gaussianité est mesurée en utilisant l'approximation de la néguentropie dans un réseau de neurones appliqué sur les sorties.

b. *JADE* (Joint Approximate Diagonalization of Eigen matrices)

Cet algorithme se base sur la méthode de diagonalisation conjointe d'un ensemble de matrices construites à partir de cumulants d'ordre 4. L'indépendance statistique est obtenue par maximisation conjointe des cumulants d'ordre 4.

c. *SOBI* (Second Order Blind Identification)

Cet algorithme de second ordre est basé sur la diagonalisation conjointe d'un ensemble de matrices de covariance.

3.4.5 Le démixage par Vertex Component Analysis VCA

La technique de VCA est une technique complètement automatique pour le démixage spectral. Elle cherche les sommets d'un simplexe qui contient les données initiales. L'algorithme est itératif et projette les données dans la direction orthogonale au sous-espace donné par les spectres sources déjà déterminés. Le spectre source suivant correspond alors à la projection la plus extrême dans cette direction. L'algorithme itère jusqu'à ce que tous les sommets correspondant au nombre de spectres sources soient déterminés [30].

La première partie du calcul consiste à déterminer le rapport signal sur bruit SNR (Signal-to-Noise Ratio) lié au nombre de sources et au niveau de bruit SNR théorique. En fonction des résultats, on appliquera l'une des deux projections suivante :

- *Projectiv Projection*
- *Subspace Projection*

Ensuite le calcul se poursuit par la recherche des pixels les plus purs correspondant donc aux sources initiales et par la génération de la matrice de démixage. Les seuls paramètres

d'entrée sont le nombre de sources (Endmembers) et les données issues de l'image sous forme matricielle

3.5 Conclusion

Dans ce chapitre nous avons cité les différentes techniques appliquées sur les images satellitaires pour le démixage spectral. Nous avons plus particulièrement détaillé une approche supervisée, à travers l'étude de la Mise en Correspondance Spectrale (MCS). Parmi les approches non supervisées, nous nous sommes intéressés à l'Analyse en Composante Indépendante (ACI) et la méthode du Vertex Component Analysis (VCA). Pour la Mise en Correspondance Spectrale, nous avons présenté différentes mesures de similarité (SDS, SVS, SCS et MCE) qui conduisent à en modifier le comportement et l'efficacité. La description de l'Analyse en Composantes Indépendantes a permis de confirmer sa capacité à séparer les mélanges non gaussiens, ou comportant au plus une source gaussienne. Enfin, nous avons proposé un canevas pour l'adaptation des techniques d'ACI à la cartographie dans un contexte d'imagerie satellitaire.

CHAPITRE4

MISE EN ŒUVRE ET APPLICATION DU SYSTEME DE DEMIXAGE

4.1 Introduction

Dans ce chapitre, nous présentons l'application des méthodes décrites dans le chapitre précédent. L'objectif consiste à analyser les images multispectrales par ces techniques afin de construire une carte d'occupation du sol des matériaux ou des objets existants.

Pour cela, notre démarche méthodologique suit plusieurs scénarios. Nous avons utilisé le démixage à travers (1) les techniques de mise en correspondance spectral (MCS), (2) l'analyse en composantes indépendantes (ACI) et (3) par vertex components analysis (VCA). Nous avons également décrit une technique de fusion par laquelle nous essayons d'améliorer les résultats de classification. Par la suite, nous avons établi deux classifications hybrides dans lesquelles nous combinons entre ces techniques. Les organigrammes global et détaillé de la méthodologie suivie pour atteindre ces objectifs sont illustrés dans les figures suivantes.

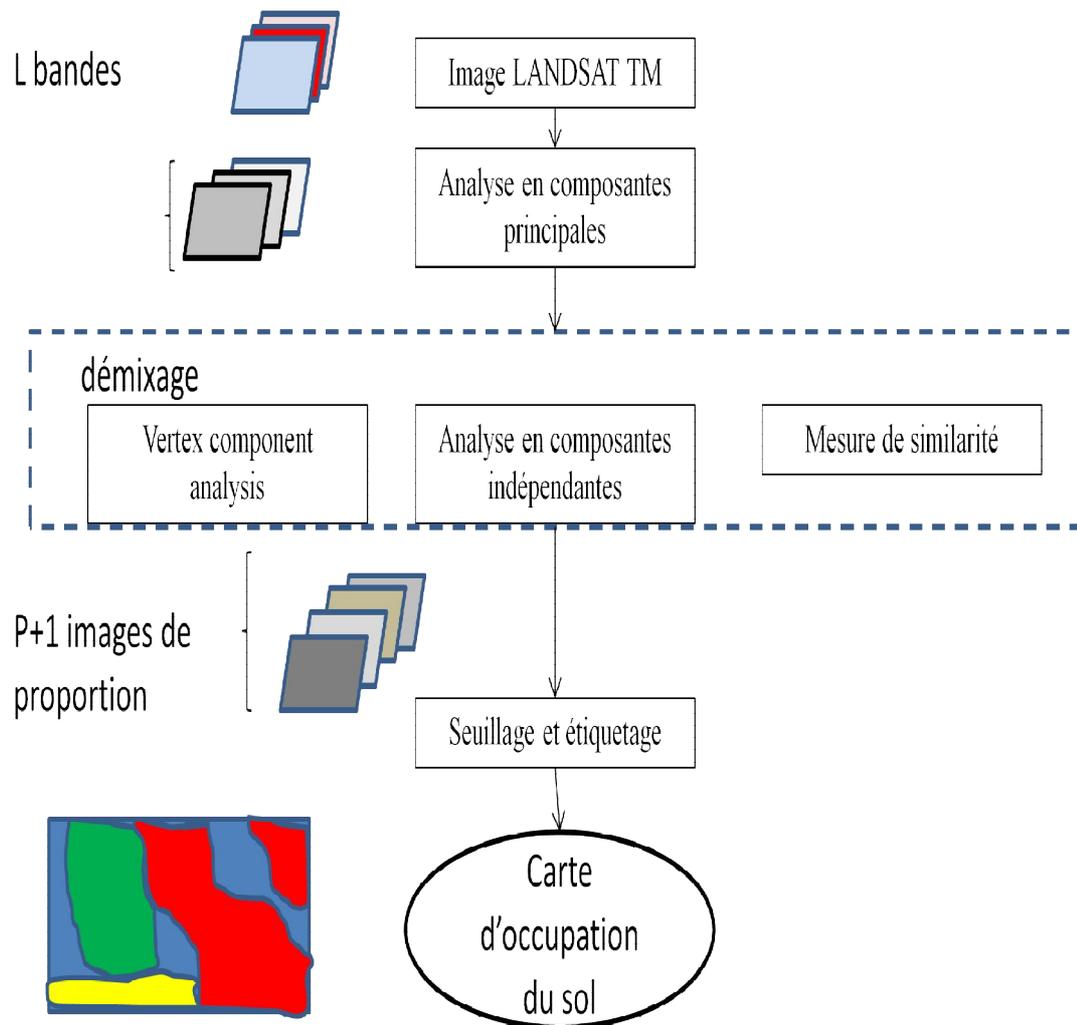


Figure 4.1 Organigramme global du système développé

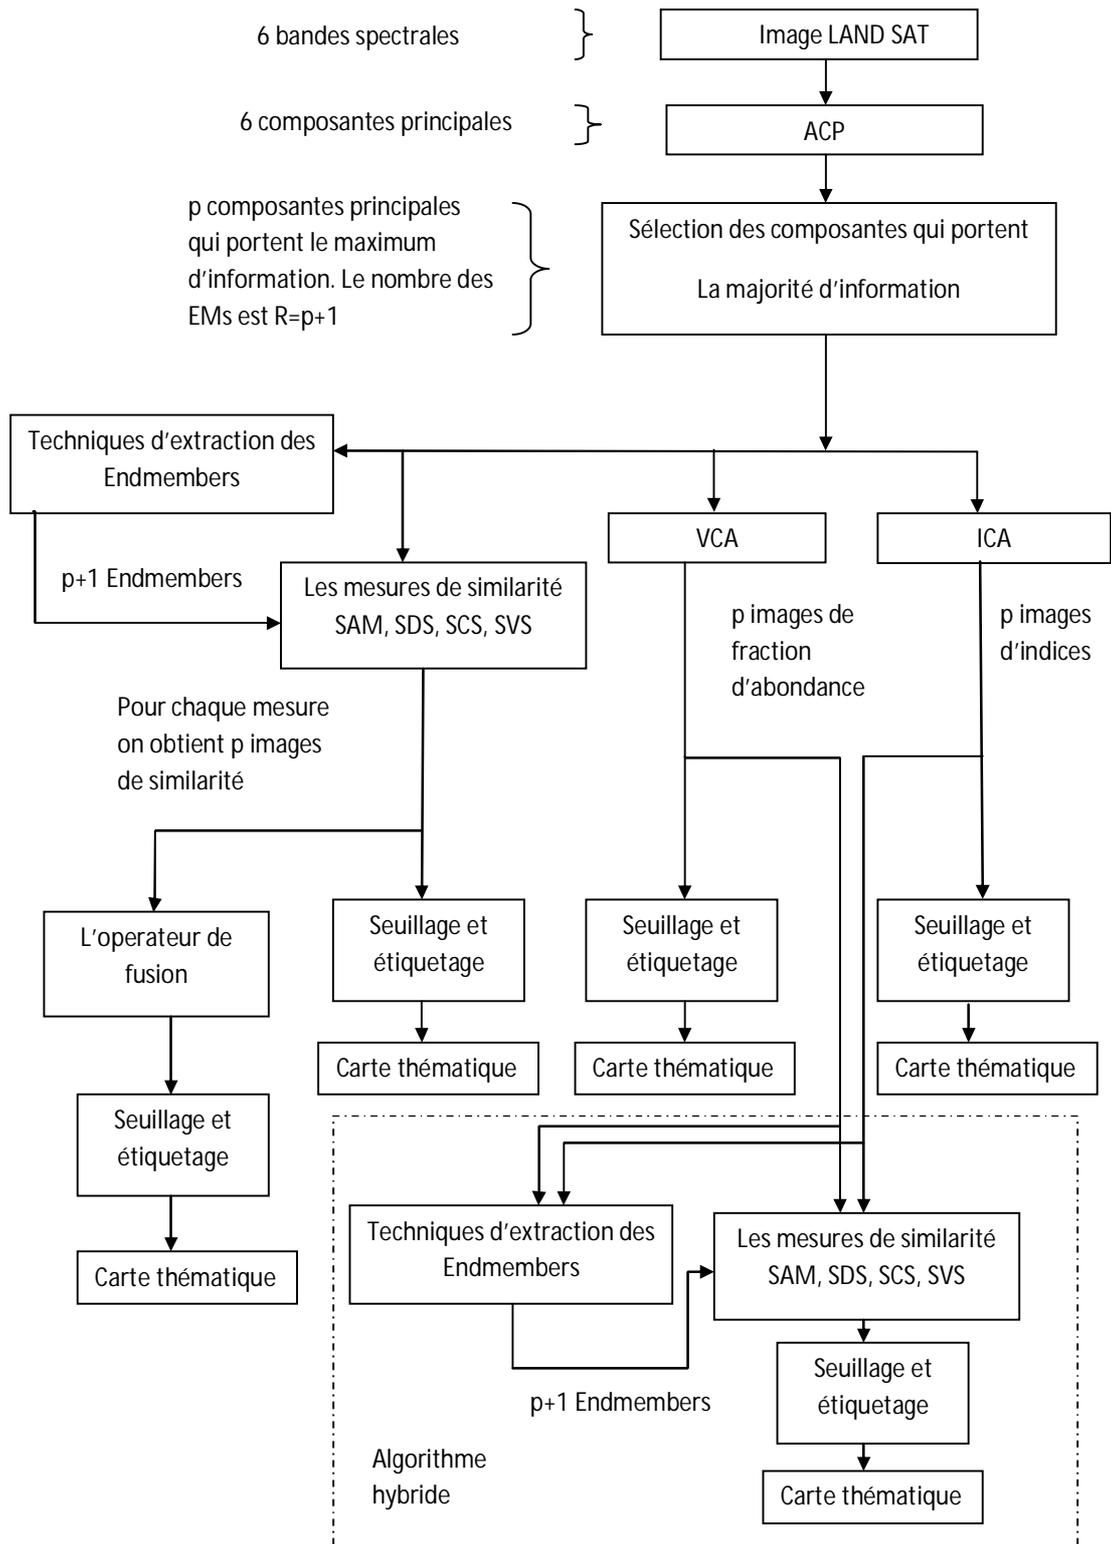


Figure 4.2 Synop

Figure 4.2 : Synoptique détaillé du système développé

4.2 Matériels est données

2.4.1 Les images satellitaires

Nous avons utilisé les images LANDSAT TM qui comportent six bandes spectrales avec une résolution de 30 mètres.

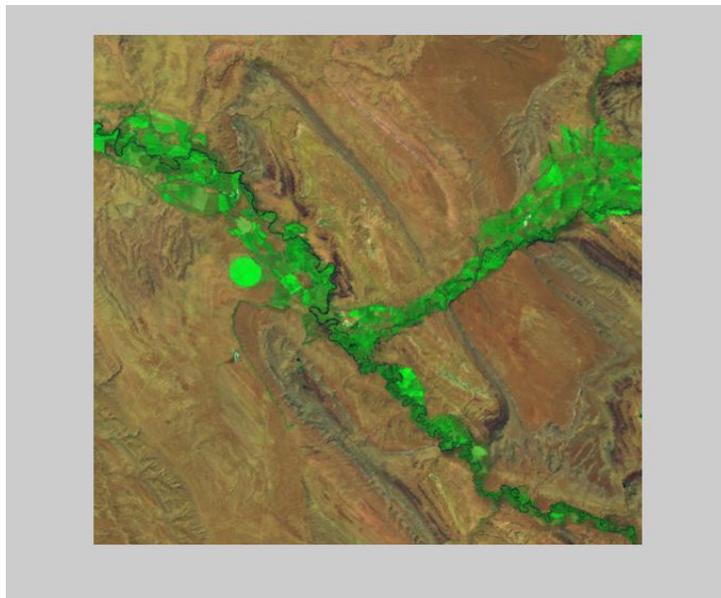


Figure 4.3 : Image LANDSAT TM (BIGORN BASIN .USA ; Dimension : 512x512x6 ;
Longueur d'onde : 0.485 - 2.215 μm)



Figure 4.4 Image LANDSAT TM (Canon City, Colorado.USA; Dimension : 640x400 x6 ;
Longueur d'onde : 0.485 - 2.215 μm)

4.2.2 Environnement et langage de programmation

Vues sa facilité d'utilisation et les performances qu'il offre, nous avons opté pour le langage MATLAB. Il est possible de créer ses propres algorithmes suivant le langage de programmation sur MATLAB (fichier .m). Ce langage de programmation est très intuitif. Son avantage par rapport à certains langages réside dans le fait que beaucoup de fonctions sont préprogrammées. La version du MATLAB utilisée dans le présent travail est MATLAB 7.11.0 (R2010b). Le système d'exploitation utilisé est le Microsoft Windows 7.

Afin de présenter les résultats obtenus nous avons construit une interface graphique, à partir de laquelle on peut ouvrir une image LANDSAT et effectuer les différentes classifications. L'évaluation des traitements se fait par le calcul de la matrice de confusion (cf. Figure 4.3).

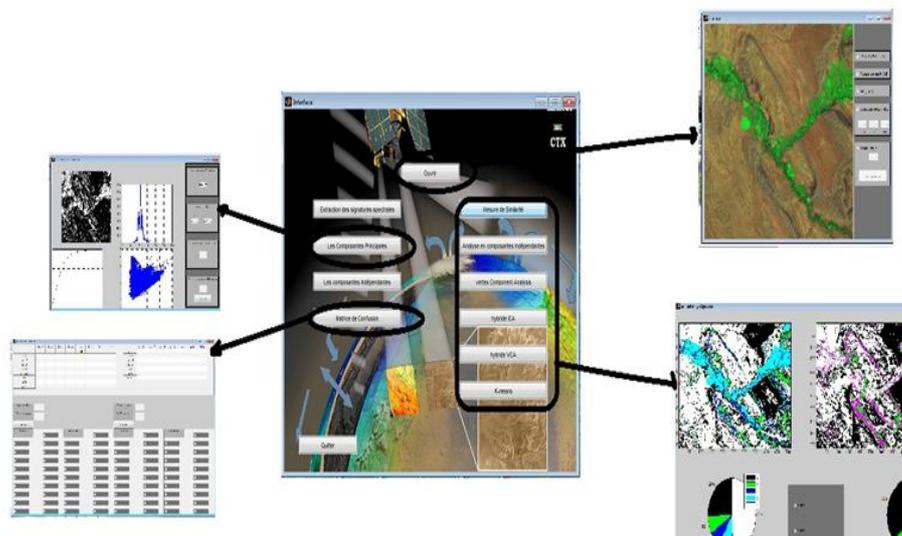


Figure 4.5 : La fenêtre principale et modules y afférents

Lors de l'ouverture de la fenêtre principale tous les boutons sont inactifs sauf le bouton ouvrir et quitter. L'activation des boutons nécessite l'ouverture de l'image. Pour effectuer une classification, il faut d'abord réaliser un prétraitement par une des opérations suivantes : ACP, ACI et extraction des Endmembers.

4.3 Analyse en composantes principales

L'analyse en composantes principales (ACP), permet d'étudier les données dans un espace de dimension réduite. Une ACP revient à remplacer les attributs qui sont corrélés, par de nouvelles variables: les composantes principales [32].

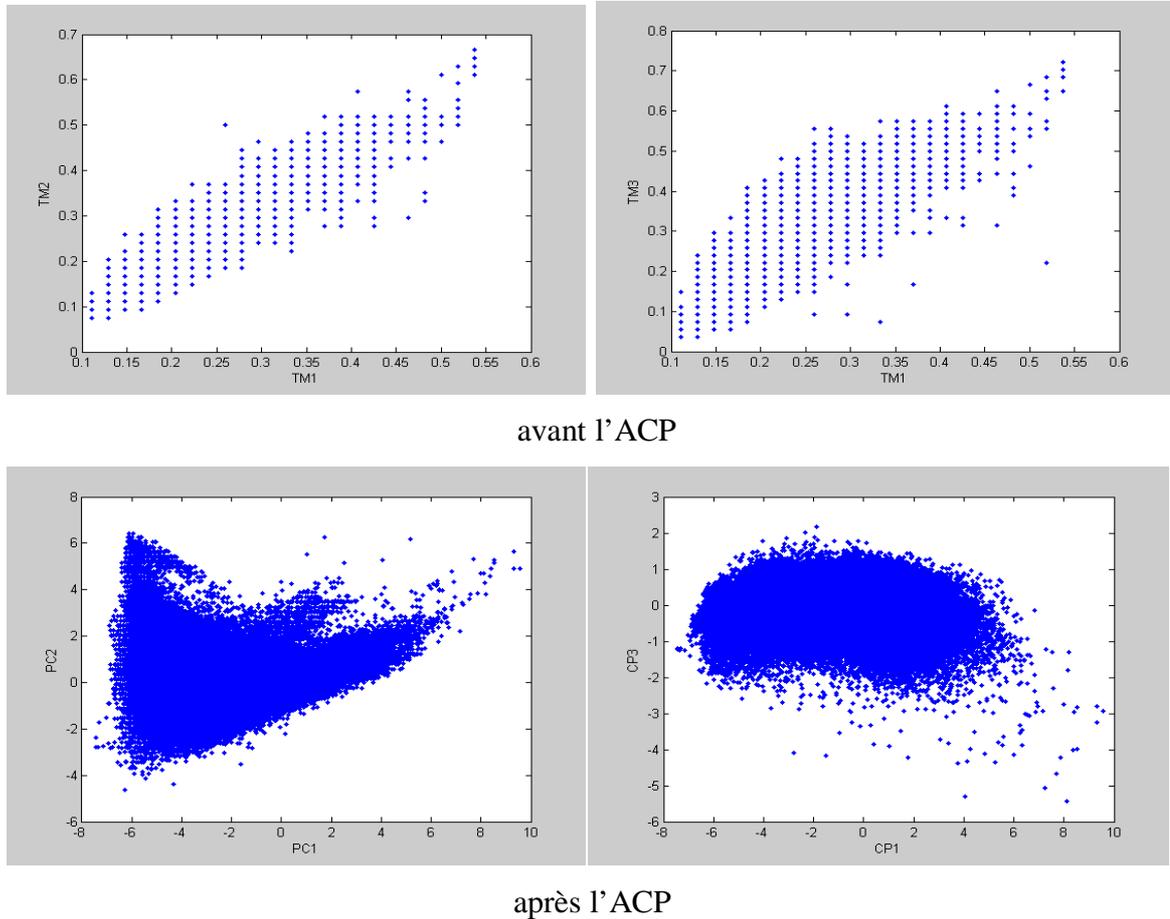


Figure 4.6 : Le nuage des points
(BIGORN BASIN.USA)

Les canaux	Tm1	Tm2	Tm3	Tm4	Tm5	Tm7
Tm1	1					
Tm2	0.9568	1				
Tm3	0.9380	0.9793	1			
Tm4	0.0130	0.1187	0.0803	1		
Tm5	0.8070	0.8486	0.8807	0.0925	1	
Tm7	0.8454	0.8691	0.8995	-0.0703	0.9594	1

Tableau 4.1 : La corrélation entre les différents canaux de l'image
(BIGORN BASIN.USA)

Selon le tableau 4.1 on constate une forte corrélation entre les bandes spectrales de l'image, comme par exemple les bandes TM1 et TM2 corrélerent bien entre elles ; le coefficient de corrélation vaut 0.9568. Elles contiennent pratiquement les mêmes informations. Par contre TM1 et TM4 ne corrélerent pas bien, le coefficient de corrélation vaut 0.0130.

entropie	Canal 1	Canal 2	Canal 3	Canal 4	Canal 5	Canal 6
Image multispectrale	3.2310	3.7316	4.0682	4.1608	4.4038	4.5207
Les CPs	3.5935	4.042	5.1559	4.4047	4.0915	3.9203

Tableau 4.2 : Entropie d'image
(BIGORN BASIN.USA)

Le calcul de l'entropie nous permet de connaître la quantité d'information dans chaque bande de l'image. D'après le tableau 4.2, la bande TM4 qui ne corréle pas avec les bandes TM1 et TM2 et qui a une entropie de 4.1608 contient des informations absentes dans TM1 et TM2.

Les Cps	Cp1	Cp2	Cp3	Cp4	Cp5	Cp6
Cp1	1					
Cp2	0	1				
Cp3	0	0	1			
Cp4	0	0	0	1		
Cp5	0	0	0	0	1	
Cp6	0	0	0	0	0	1

Tableau 4.3 : La corrélation entre les composantes principales

Les Cps	Cp1	Cp2	Cp3	Cp4	Cp5	Cp6
Les paramètres						
Valeurs propres	4.5978	1.0214	0.2893	0.0528	0.0240	0.0148
%d'information apportée par chaque composante (%)	76.63	17.02	4.82	0.88	0.4	0.25

% d'information cumulée (%)	67.63	93.65	98.47	99.35	99.75	100
------------------------------------	-------	-------	-------	-------	-------	-----

Tableau 4.4 : Résultats de l'ACP

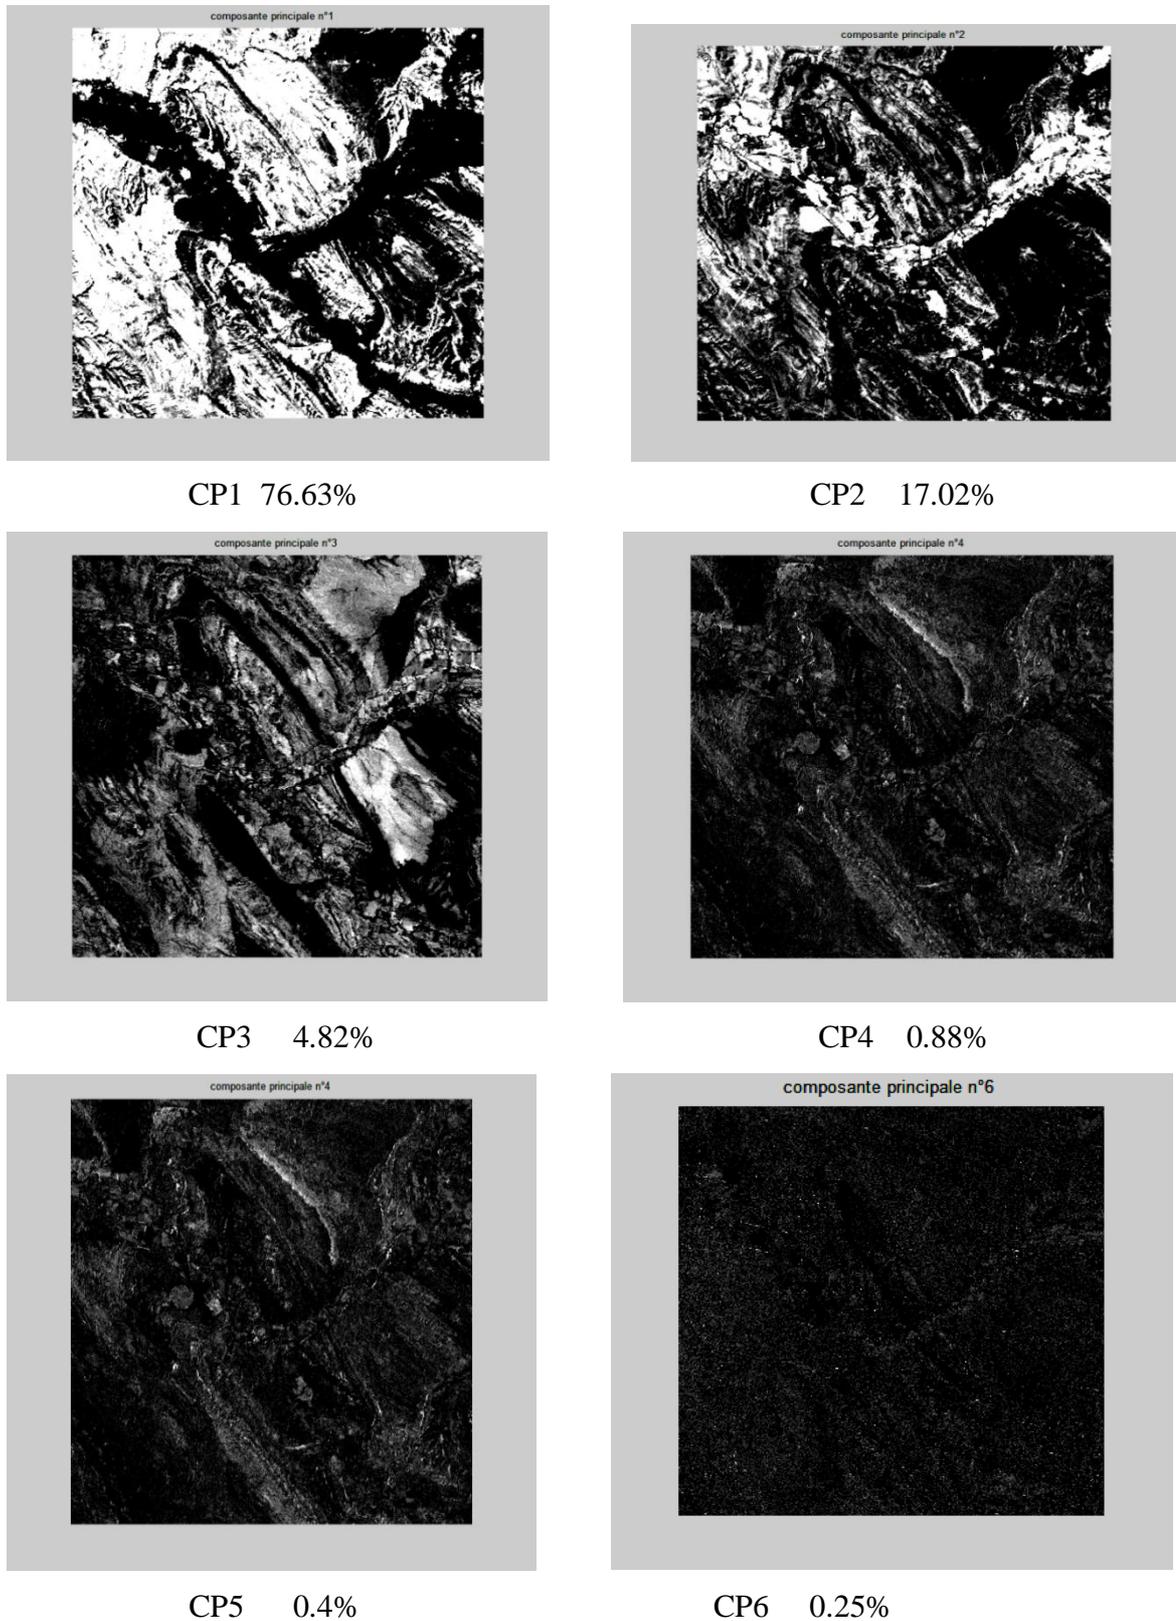


Figure 4.7 : Les composantes principales de l'image BIGORN BASIN, USA

La sortie de l'ACP fournit des composantes qui ont des coefficients de corrélation nulle ; ceci implique que la redondance d'informations présentes dans l'image multispectrale est éliminée (tableau 4.3).

D'après le tableau 4.3, les trois premières composantes principales apportent presque toute l'information présente dans les 6 bandes spectrales de l'image. En effet, le pourcentage cumulé d'informations apportées par ces 3 composantes est de 98.45%, ce qui conduit à utiliser seulement ces 3 composantes.

L'analyse en composantes principales permet de rehausser la qualité d'une image multispectrale en éliminant la redondance des données contenues dans les différents canaux d'une image multispectrale. Le volume des données restant à manipuler se résume aux trois ou quatre composantes principales.

4.4 Application des techniques de mise en correspondance

Les techniques étant supervisées, elles nécessitent une étape de détermination des Endmembers. Ces derniers correspondent aux vecteurs de références qui contiennent des connaissances sur les objets ou matériaux présentent dans la scène. L'organigramme de classification est illustré sur la figure suivante.

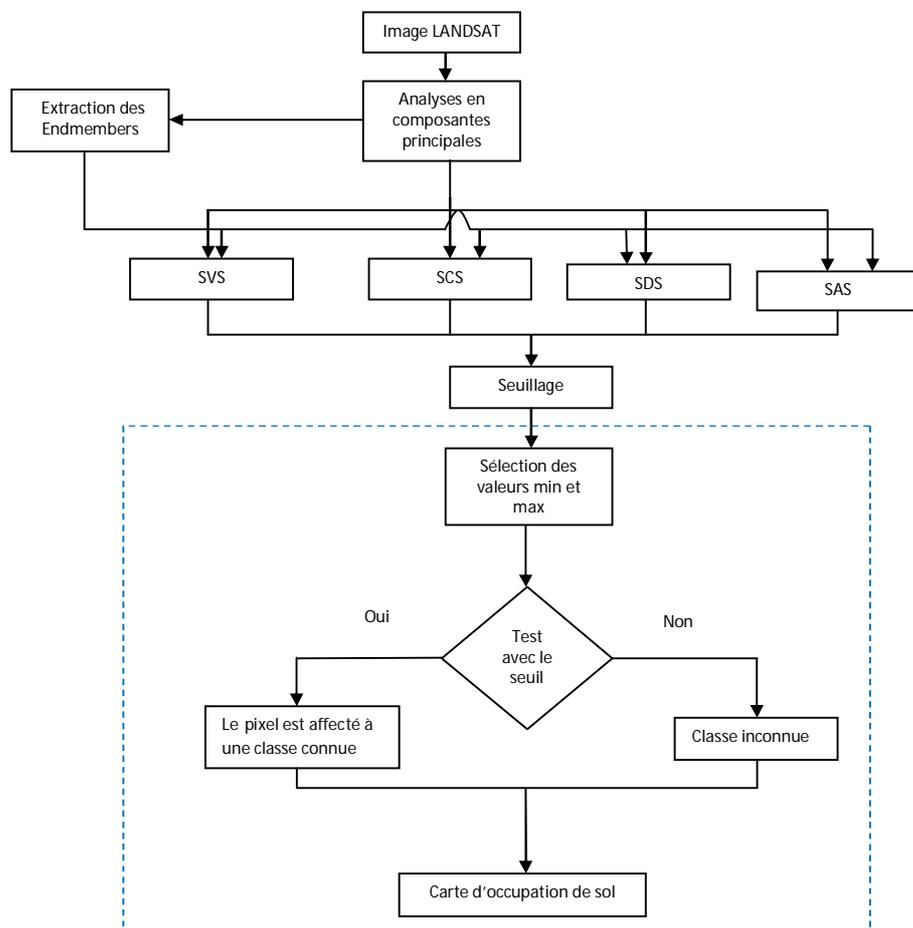


Figure 4.8 : Organigramme des méthodes de mise en correspondance spectrale

4.4.1 Extraction des signatures spectrales

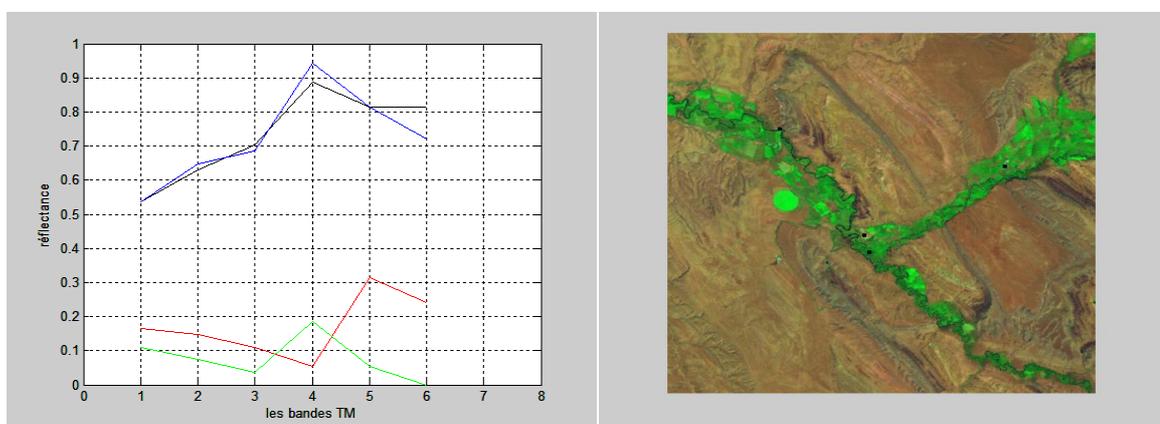
Nous avons extrait l'information sur les différentes classes d'objets à partir des composantes principales, à l'aide des méthodes d'extraction des signatures spectrales. Nous avons utilisé six méthodes, à savoir : PPI, N-FINDER, ATGP, VCA, POLYGONE OPTIMAL, ACI.

Pour connaître le nombre de sources existantes dans l'image, nous avons utilisé l'équation (3.25) pour déterminer le nombre des composantes principales à partir desquelles il n'y a plus d'information importante dans les CPs (pour notre cas $p=3$ pour 97% d'information). Le nombre des EMs sera donc $R=p+1$.

a. Méthode de calcul du PPI

L'identification de pixels spectralement purs dans une image de télédétection est faite par le calcul de l'indice de pureté du pixel (PPI). Ces pixels représentent des composantes spectrales homogènes au sol [33]. Il s'agit d'une procédure répétitive des opérations suivantes :

- création au hasard d'un vecteur ancré à l'origine de l'espace spectral,
- projection des points du nuage sur ce vecteur,
- marquage des pixels à l'intérieur d'un seuil des valeurs minimales et maximales comme étant extrêmes. De cette façon, on produit une image où la valeur du pixel représente le nombre de fois que le pixel a été identifié comme extrême. Ces extrêmes représentent les pixels purs de l'image, ce qui correspond aux signatures prototypes recherchées.



les spectres des endmembers

l'ocalisation géographique

des Endmembers

Figure 4.9 :Les resultats obtenus par PPI

b. Méthode du ‘‘N-FINDER’’

La N-FINDER [34], est une technique automatique qui cherche l’ensemble des points extrêmes d’un nuage de points qui forment le plus grand volume possible.

Algorithme[35] :

-Soit p le nombre des EMs nécessaire.

-Appliquer l’ACP pour réduire le nombre des bandes spectrales p tel que $p=R-1$.

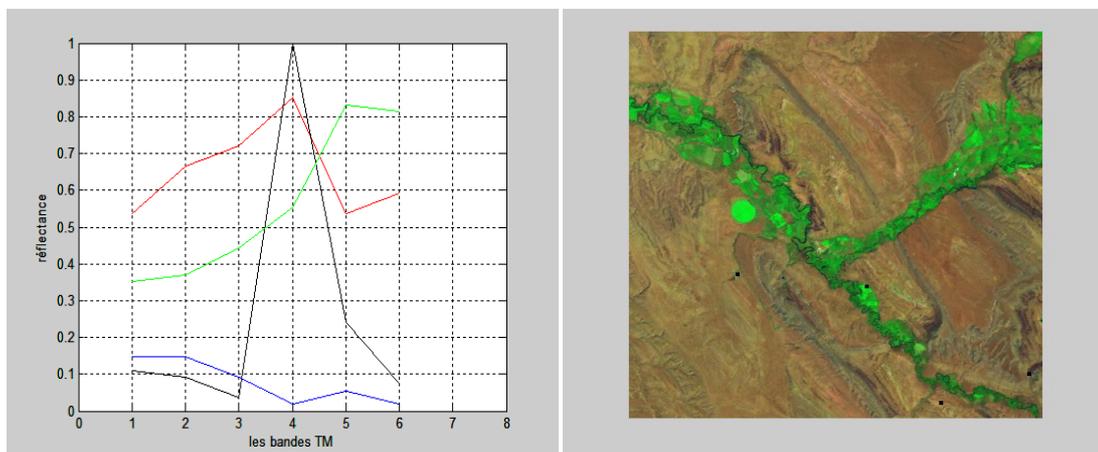
1-Sélectionner R vecteur aléatoirement à partir des données e_1, e_2, \dots, e_R qui forment le simplexe spécifier par $s(e_1, e_2, \dots, e_R)$ et calculer leur volume $v(e_1, e_2, \dots, e_R)$ par l’équation :

$$v(e_1, e_2, \dots, e_R) = \frac{\left| \det \begin{bmatrix} 1 & 1 & \dots & 1 \\ \vdots & \vdots & \vdots & \vdots \\ e_1 & e_2 & \dots & e_R \end{bmatrix} \right|}{p!}$$

2-Rechercher l’ensemble des R vecteurs parmi les données désignés $(e_1^*, e_2^*, \dots, e_R^*)$, qui forment le simplexe à volume maximal i.e. :

$$\{e_1^*, e_2^*, \dots, e_R^*\} = \arg \{ \max_{\{e_1, e_2, \dots, e_R\}} v(e_1, e_2, \dots, e_R) \}$$

3-Soit $\{e_1^*, e_2^*, \dots, e_R^*\}$ l’ensemble des EMs estimées.



les spectres des endmembers

l'ocalisation géographique
des Endmembers

Figure 4.10 :Les resultats obtenus par N-FINDER

c. Méthode ‘‘Automated Target Generation Process (ATGP)’’

L’ATGP a été développé par [36], dans le but de trouver des pixels qui peuvent être utilisés pour générer une matrice des EMs pour une projection orthogonale. L’idée de base

de l'ATGP est de rechercher les pixels les plus distinctifs en utilisant la similarité métrique des pixels : le pixel qui est le plus distinctif est celui qui a la projection orthogonale maximale dans le sous espace engendré par les autres pixels. L'algorithme ATGP suit les étapes ci-dessous:

1. Sélectionner une signature initiale notée e_0 . Le bon choix correspond au pixel qui a la norme maximale
2. Appliquer l'opérateur de projection orthogonale P^\perp (OSP orthogonal subspace projection) à chaque pixel r , mettre $i=0$ et $U_0 = e_0$

$$P_{e_0}^\perp = I - e_0(e_0^T e_0)^{-1} e_0^T \quad \text{où } I \text{ est la matrice Identité}$$

3. trouver le premier EM désigné par e_1 qui présente la projection orthogonale maximale :

$$e_1 = \arg \{ \max_r [(P_{e_0}^\perp r)^{-1} (P_{e_0}^\perp r)] \}$$

Mettre $i=1$ et $U_1 = e_1$

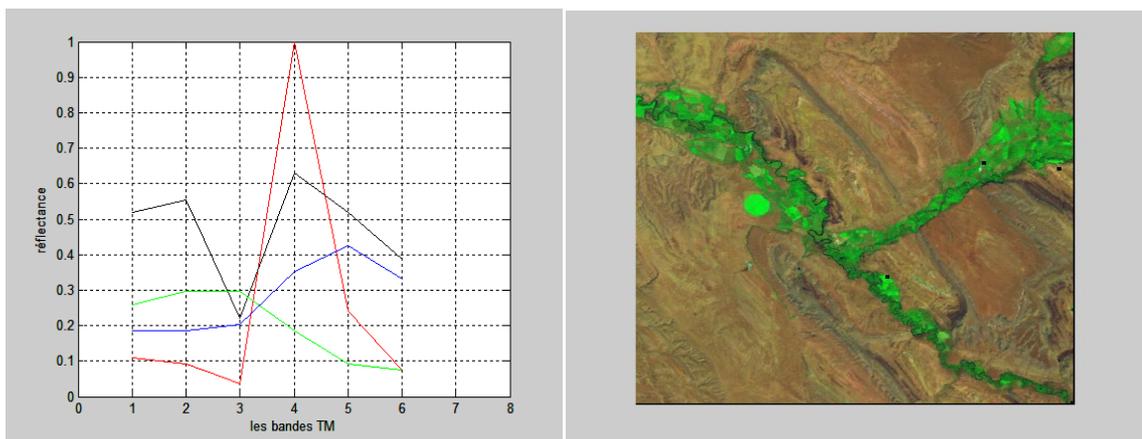
4. Trouver le i^{eme} EM a la i^{ieme} étape par :

$$e_i = \arg \{ \max_r [(P_{U_{i-1}}^\perp r)^{-1} (P_{U_{i-1}}^\perp r)] \}$$

où la matrice des EMs $U_{i-1} = [e_1 \ e_2 \ \dots \ e_{i-1}]$ est générée à la i^{ieme} étape

5. Terminer l'algorithme si le nombre des EMs est atteint, sinon retourner à l'étape 4

Une application de cet algorithme est donnée par la figure 4.10.



les spectres des endmembers

localisation géographique
des Endmembers

Figure 4.11 :les resultats obtenus par ATGP

d. *Extraction par le polygone optimal*

Cette methode est basée sur le fait que les EMs sont les sommets d'un polygone, qui est dessiné a partir d'un simplex du nuage du points.

Algorithme [35] :

entrée : S un ensemble de points.

u = le point le plus bas de S ;

$min = \infty$

Pour tout $w \in S \setminus \{u\}$

si $angle(u, w) < min$ alors $min = angle(u, w)$; $v = w$;

$u.suivant = v$;

Faire

$S = S \setminus \{v\}$

Pour tout $w \in S$

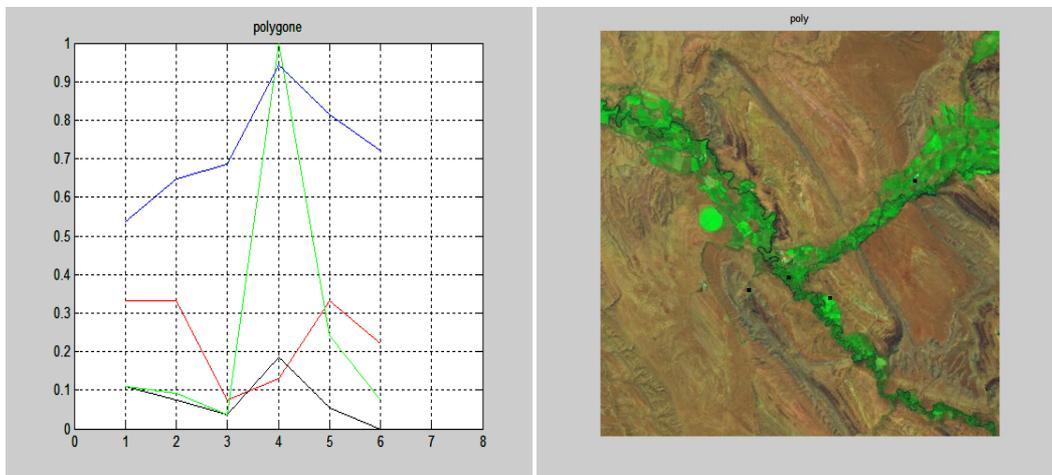
$min = \infty$

si $angle(v.pred, v, w) < min$ alors

$min = angle(v.pred, v, w)$; $v.suivant = w$;

$v = v.suivant$;

Tant que $v \neq u$



les spectres des endmembers

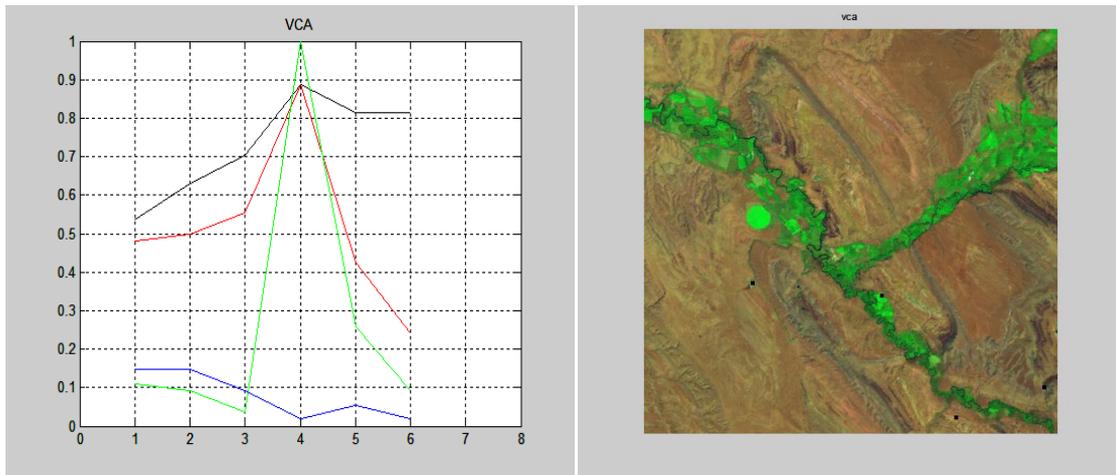
localisation géographique
des Endmembers

Figure 4.12 :les resultats obtenus par le polygone optimal

e. Extraction des Ems par VCA

VCA suppose la présence des pixels purs dans les données, et projetés de façon itérative sur la direction orthogonale à l'espace engendré par les EMs qui sont déjà déterminés. La nouvelle signature spectrale correspond à l'extrême de la projection, le

reste des valeurs de projection correspondent à la fraction d'abondance de cette signature spectrale.



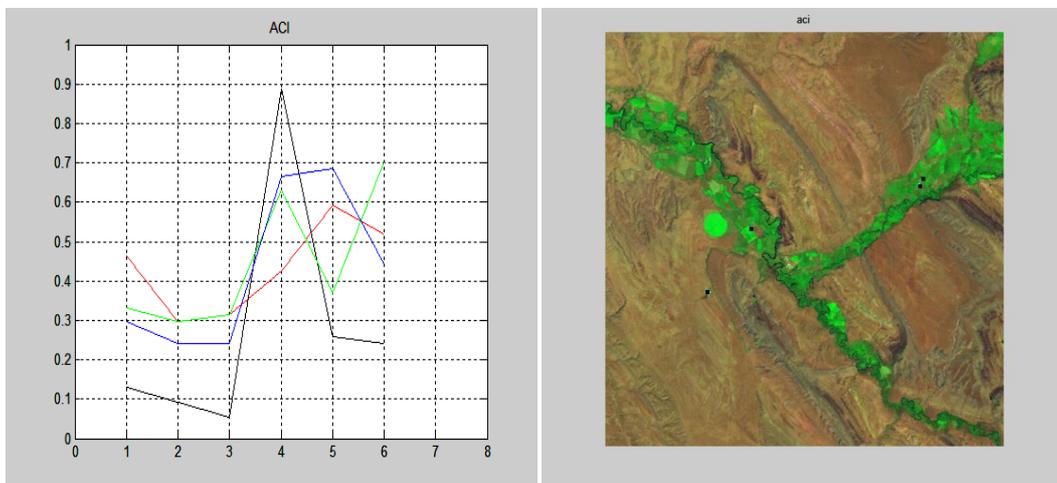
les spectres des endmembers

localisation géographique
des Endmembers

Figure 4.13 : les resultats obtenus par la VCA

f. Extraction des Ems par ACI

En utilisant l'équation (3.38) on peut trouver les Endmembers par ACI



les spectres des Endmembers

localisation géographique
des Endmembers

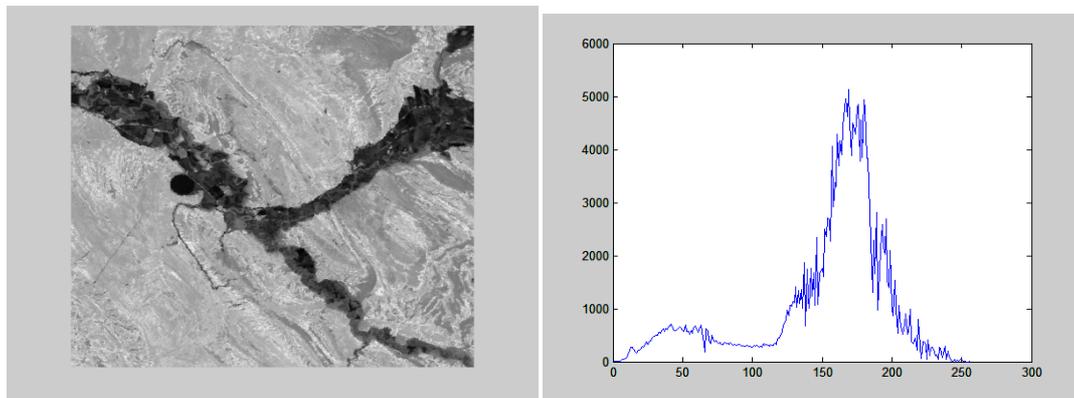
Figure 4.14 : les résultats obtenus par l'ACI

4.4.2 Calcul des images de similarité

Pour chaque classe en fonction des différentes mesures nous pouvons calculer différentes images de similarité.

4.4.2.1 L'angle spectral SAM (Spectral Angle Mapper)

Nous avons estimé la mesure SAM en utilisant l'équation (3.8). Dans le cas idéal les valeurs de similarité sont nulles. La figure.4.14(a) montre une image de similarité correspondante à une classe. D'après l'équation (3.8), les pixels les plus sombres sont les pixels similaires à la référence. En considérant l'histogramme de l'image de similarité (figure.4.14(b)), nous observons la présence de pics. Le pic proche de zéro en particulier, correspond aux pixels ayant un spectre similaire au vecteur de référence. Ce pic peut facilement être isolé de façon automatique.



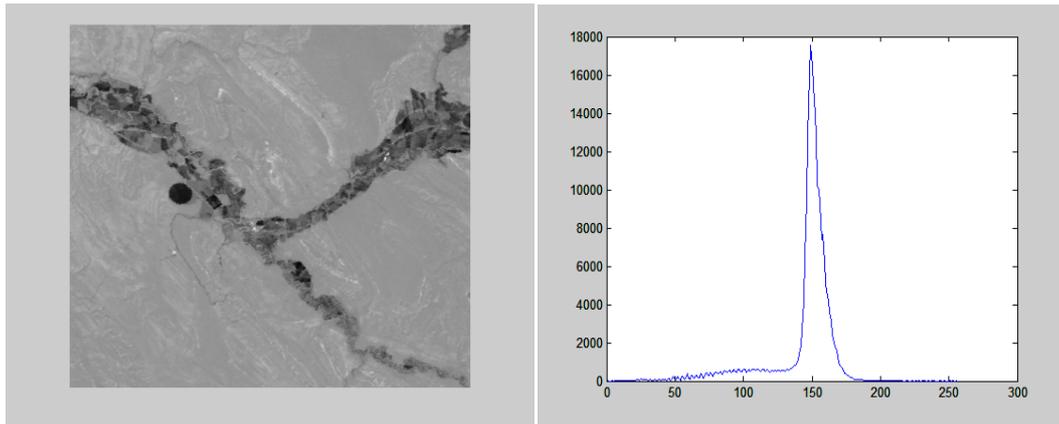
L'image de similarité

Histogramme

Figure.4.15: Les images de similarité obtenues par SAM
(BIGORN BASIN.USA)

4.4.2.2 La Similarité de Distance Spectrale (SDS)

L'image de similarité par SDS est calculée de la même façon que le SAM. En effet, nous avons calculé la distance euclidienne entre le vecteur de référence et le vecteur de chaque pixel en utilisant l'équation (3.9). Ensuite, nous la normalisons par l'équation (3.10). Le résultat fourni à la figure 4.15 montre l'histogramme et l'image de similarité. Évidemment, l'image de similarité par le SDS semble moins bonne. Le contraste entre les différents matériaux est également moindre. Nous pouvons ainsi dire que la distance spectrale n'est pas satisfaisante en tant que mesure directe de similarité. De la sorte, en considérant l'histogramme de l'image de similarité, la décision pour le seuillage est relativement difficile.



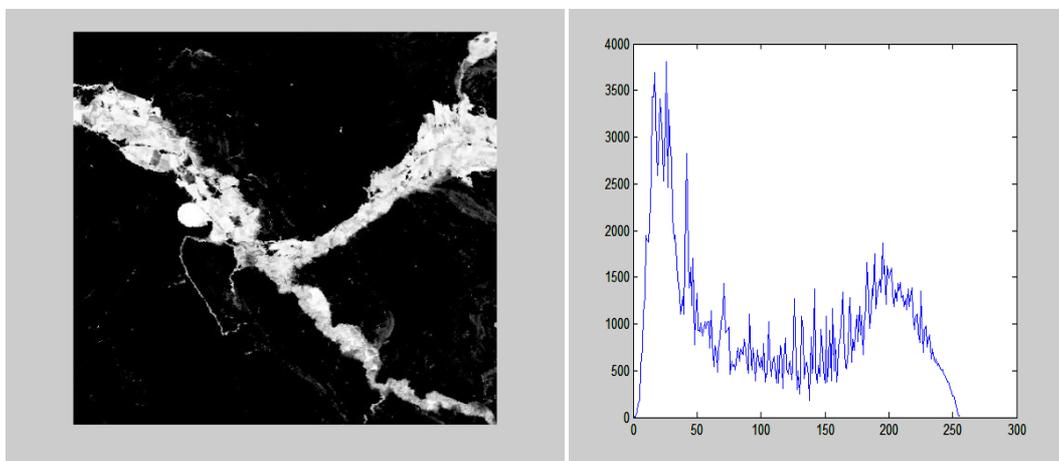
L'image de similarité

Histogramme

Figure.4.16 : Les images de similarité obtenues par SDS
(BIGORN BASIN.USA)

4.4.2.3 La Similarité de Corrélation Spectrale (SCS)

Nous avons estimé les différentes images de similarité à partir de la mesure SCS. Ces images sont obtenues par l'équation (3.11), dans lesquelles les valeurs des pixels similaires à la référence ayant obtenu le maximum de corrélation spectrale sont considérées.



L'image de similarité

Histogramme

Figure 4.17 : Les images de similarité obtenues par SCS
(BIGORN BASIN.USA)

Les pixels ayant le spectre similaire à la référence sont les pixels de la zone claire sur l'image. En considérant l'histogramme de l'image, le pic proche du un est celui qui correspond à ces pixels.

4.4.2.3 La Similarité de Valeur Spectrale (SVS)

Comme nous l'avons déjà évoqué, le SVS est une mesure combinée présentant les avantages des deux mesures précédentes. Pour calculer les images de similarité nous avons utilisé l'équation (3.12), dans laquelle les valeurs des pixels similaires à la référence ayant obtenu le minimum de valeur spectrale sont considérées. Les résultats sont illustrés sur la figure 4.17.

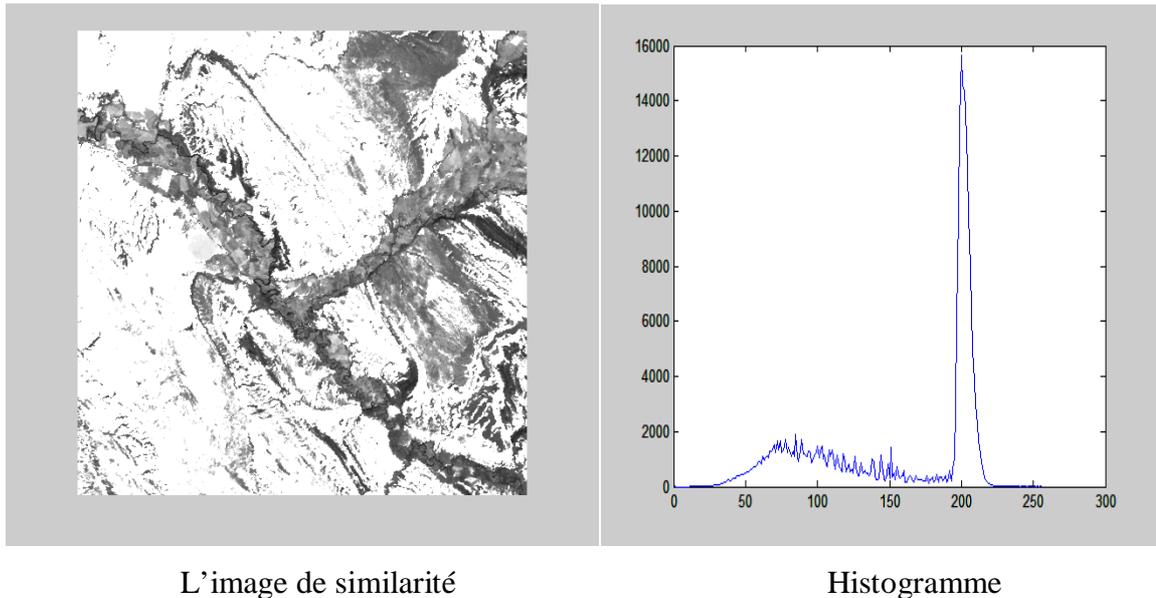


Figure 4.18 : Les image de similarité obtenues par SVS

(BIGORN BASIN.USA)

Les pixels sombres sont les pixels similaires à la référence. L'histogramme présente 2 pics. Le plus proche de zéro c'est celui qui correspond aux pixels similaires à la référence.

4.4.2.4 Conclusion

L'observation visuelle des images de similarité obtenues par différentes mesures ainsi que l'analyse visuelle des histogrammes correspondants permet de prédire sur la classification. Les images obtenues par les techniques SAS, SCS, SVS, montrent un fort contraste entre les pixels similaires et les pixels non similaires. Cette constatation s'étend aux histogrammes correspondant, dans lesquels se présentent généralement deux pics : un est relatif aux pixels ayant le même spectre que celui de référence et l'autre est relatif aux pixels non similaires. Cette forme d'histogramme nous a conduit à un seuillage facile et fiable ; par contre les images obtenues par SDS semblent moins bonne, et le contraste

entre les pixels similaires et non similaires est relativement faible. De même que pour les histogrammes, la décision pour le seuillage est relativement difficile.

4.4.3 Seuillage

Afin de séparer les pixels similaires à la référence des pixels non similaires, nous avons besoin d'un seuil pour la décision. Nous avons estimé les seuils par l'algorithme Otsu.

4.4.3.1 Définition

La méthode d'Otsu est utilisée pour effectuer un seuillage automatique à partir de la forme de l'histogramme de l'image [13]. Ceci conduit à une réduction de l'image à niveaux de gris en une image binaire. L'algorithme suppose alors que l'image à binariser ne contient que deux classes de pixels, puis calcule le seuil optimal qui sépare ces deux classes afin que leur variance intra-classe soit minimale. L'extension de la méthode originale pour faire du seuillage à plusieurs niveaux est appelée Multi Otsu method [13].

4.4.3.2 Principes

Dans la méthode d'Otsu, le seuil qui minimise la variance intra-classe est recherché à partir de tous les seuillages possibles :

$$\sigma_w^2(t) = w_1(t)\sigma_1^2(t) + w_2(t)\sigma_2^2(t) \quad (4.1)$$

Les poids w_i représentent la probabilité d'être dans la $i^{\text{ème}}$ classe, chacune étant séparée par un seuil t . Finalement, les σ_i^2 sont les variances de ces classes.

Otsu montre que minimiser la variance intra-classe revient à maximiser la variance interclasse :

$$\sigma_b^2(t) = \sigma^2(t) - \sigma_w^2(t) = w_1(t)w_2(t)[\mu_1(t) - \mu_2(t)]^2 \quad (4.2)$$

Elle est exprimée en termes des probabilités de classe w_i et des moyennes de classes μ_i qui à leur tour peuvent être mises à jour itérativement. Cette idée conduit à un algorithme efficace.

4.4.3.2 Algorithme

Calculer l'histogramme et les probabilités de chaque niveau d'intensité

Définir les $\omega_i(0)$ et $\mu_i(0)$ initiaux

Parcourir tous les seuils possibles $t = 1 \dots \text{intensité max}$

Mettre à jour ω_i et μ_i

Calculer $\sigma_b^2(t)$

Le seuil désiré correspond au $\sigma_b^2(t)$ maximum.

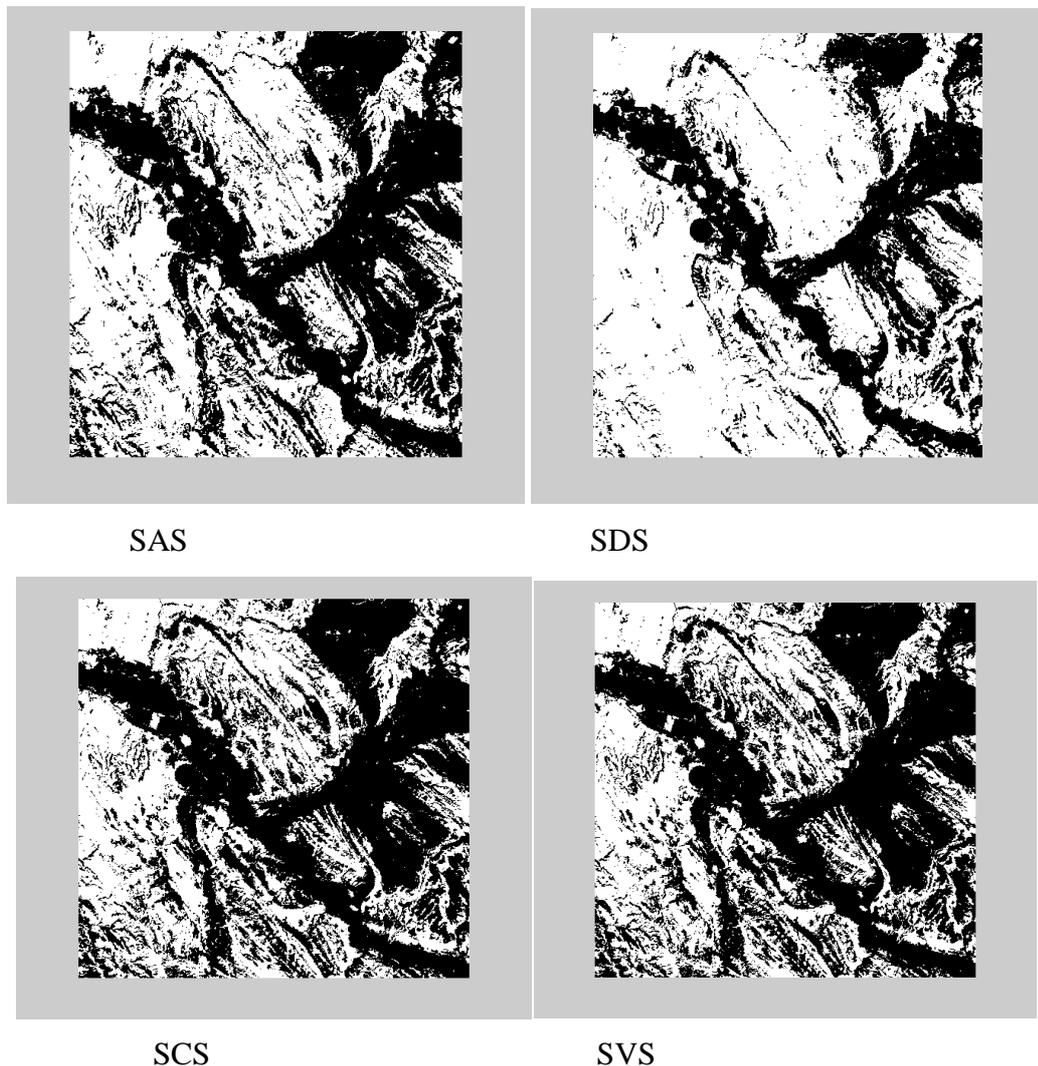


Figure 4.19 : Résultats de la binarisation (BIGORN BASIN.USA)

4.4.4 L'étiquetage

Cette étape est composée de deux parties, d'abord, la sélection de valeur minimale ou maximale de similarité, parmi p valeurs. Par exemple, si nous utilisons comme opérateur de similarité, la similarité spectrale par la corrélation, nous cherchons la valeur maximale parmi p valeurs de similarité :

$$SCS_i = \text{Max}\{SCS_1 \dots \dots \dots SCS_R\}$$

Ensuite, nous comparons ce maximum à un seuil. Si la valeur sélectionnée est supérieure à un seuil, le pixel est affecté à la classe qui maximise la similarité :

Si $SCS_i > (S_{SCS})$, le pixel est affecté à la classe i , sinon le pixel est inconnu (affecté à aucune classe). De la même façon, nous analysons l'image de similarité d'angle, de distance, et de valeur spectrale en sélectionnant les valeurs minimales.

Nous avons utilisé cet algorithme en utilisant les différentes mesures de similarité sur les images LANDSAT TM. Les figures ci-dessous montrent les différents résultats obtenus

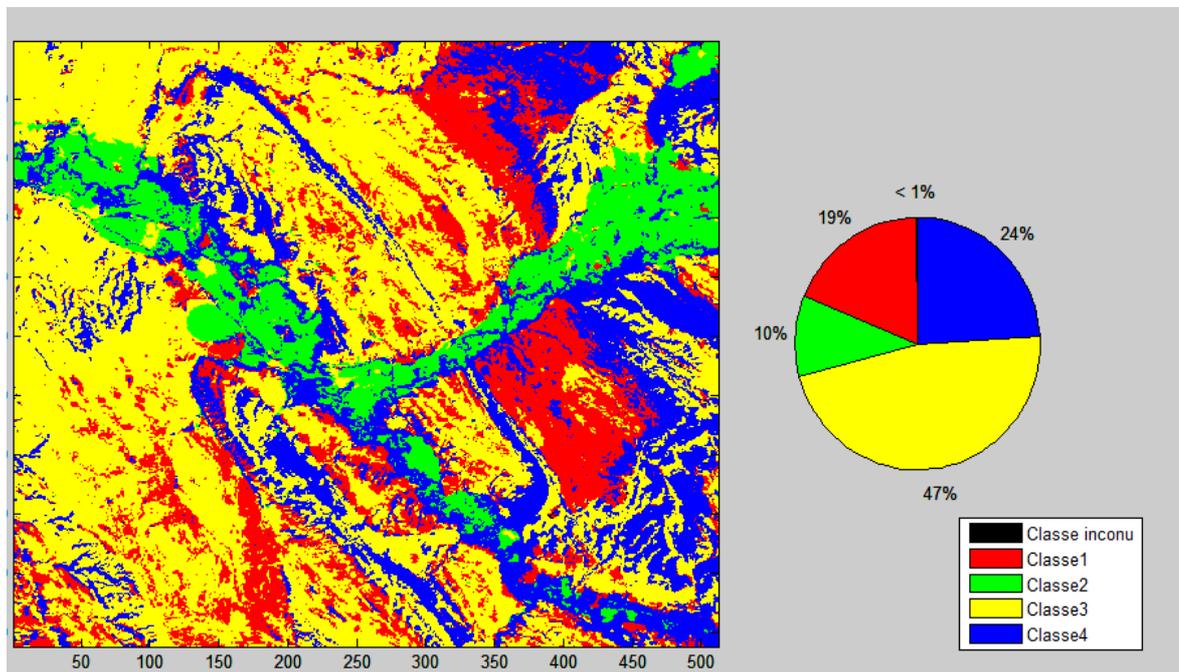


Figure 4.20 : Résultats de la classification par SAS (BIGORN BASIN.USA)

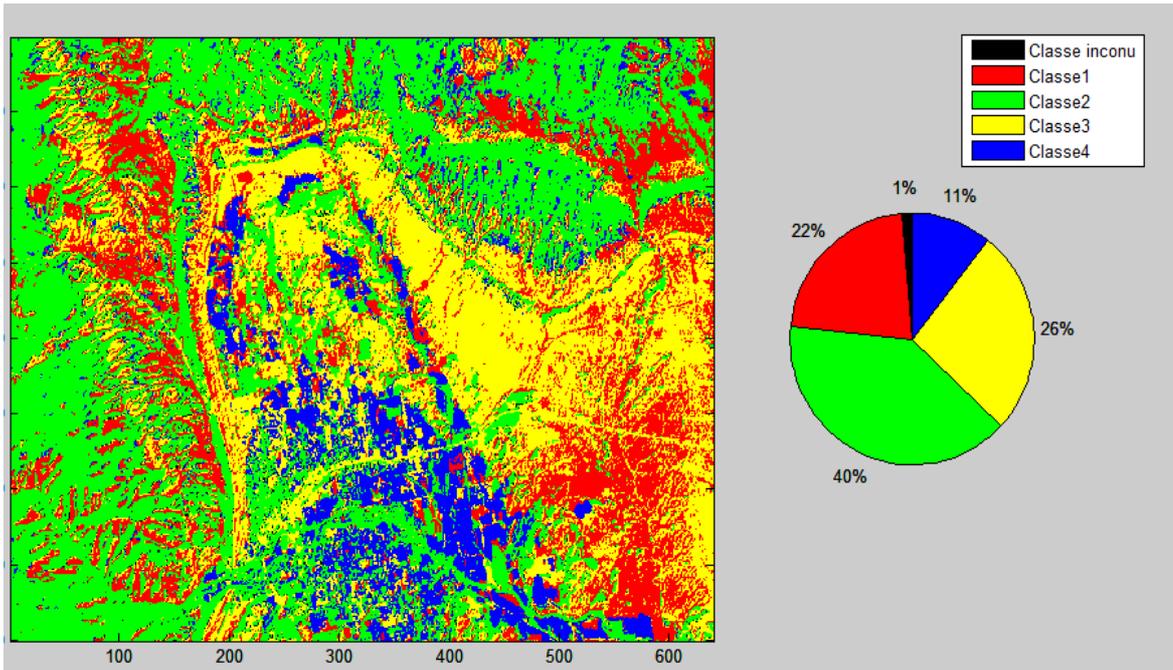


Figure 4.21 : Résultats de la classification par *SAS* (Canon City, Colorado, USA)

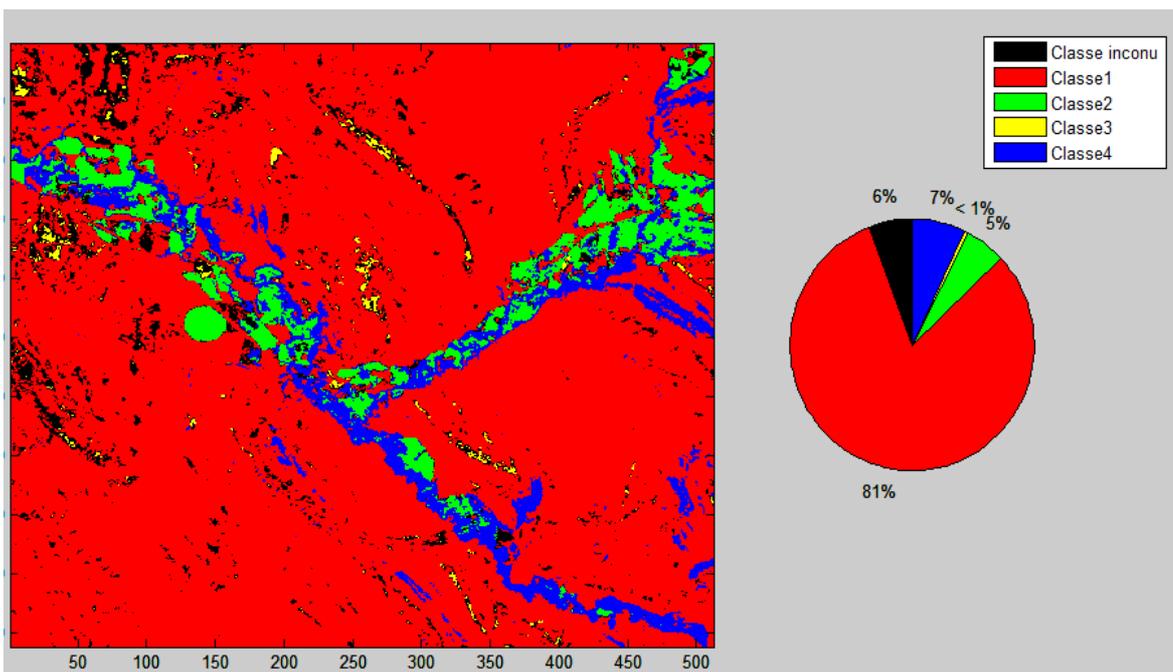


Figure 4.22 : Résultats de la classification par *SDS* (BIGORN BASIN, USA)

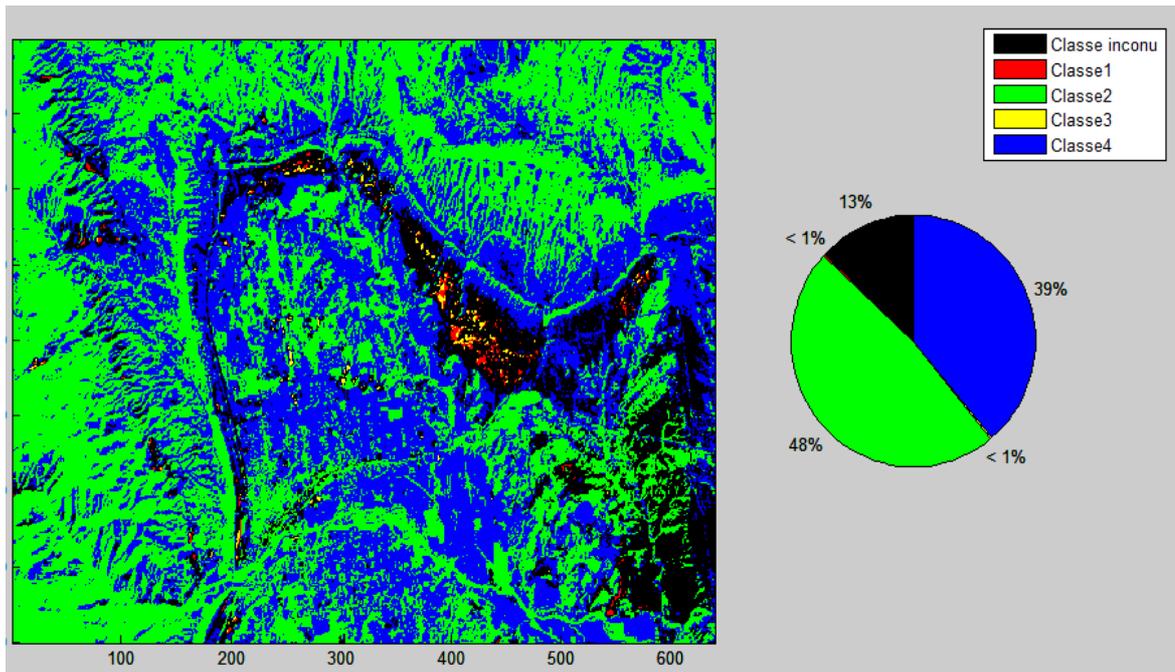


Figure 4.23 : Résultats de la classification par *SDS* (Canon City, Colorado, USA)

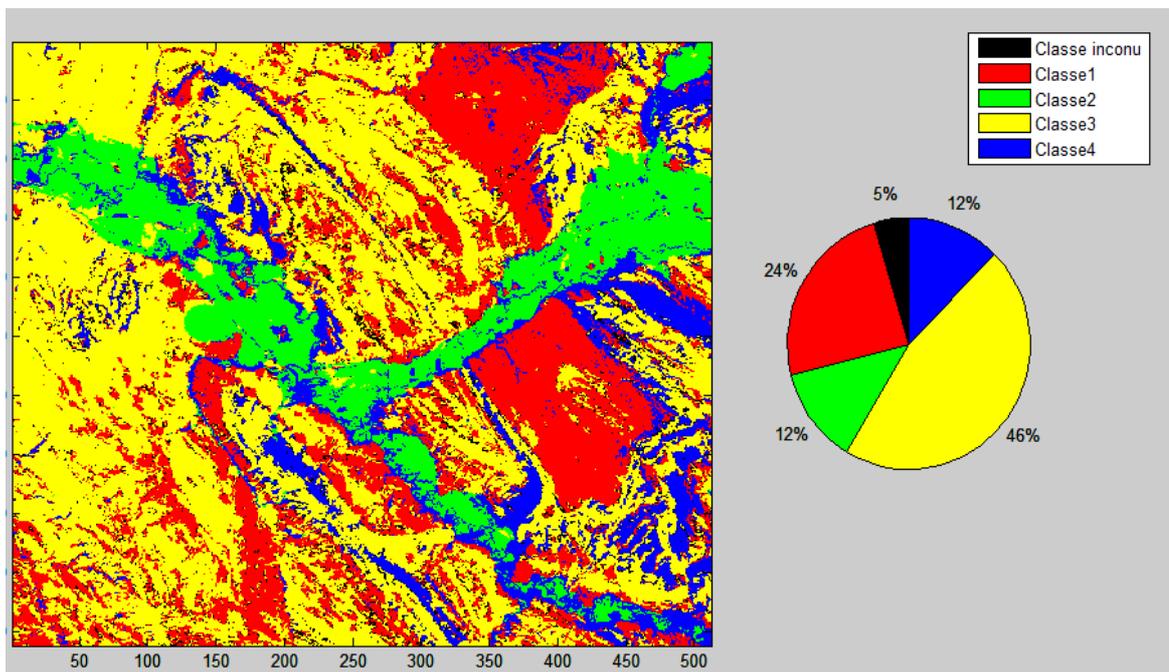


Figure 4.24 : Résultats de la classification par *SCS* (BIGORN BASIN .USA)

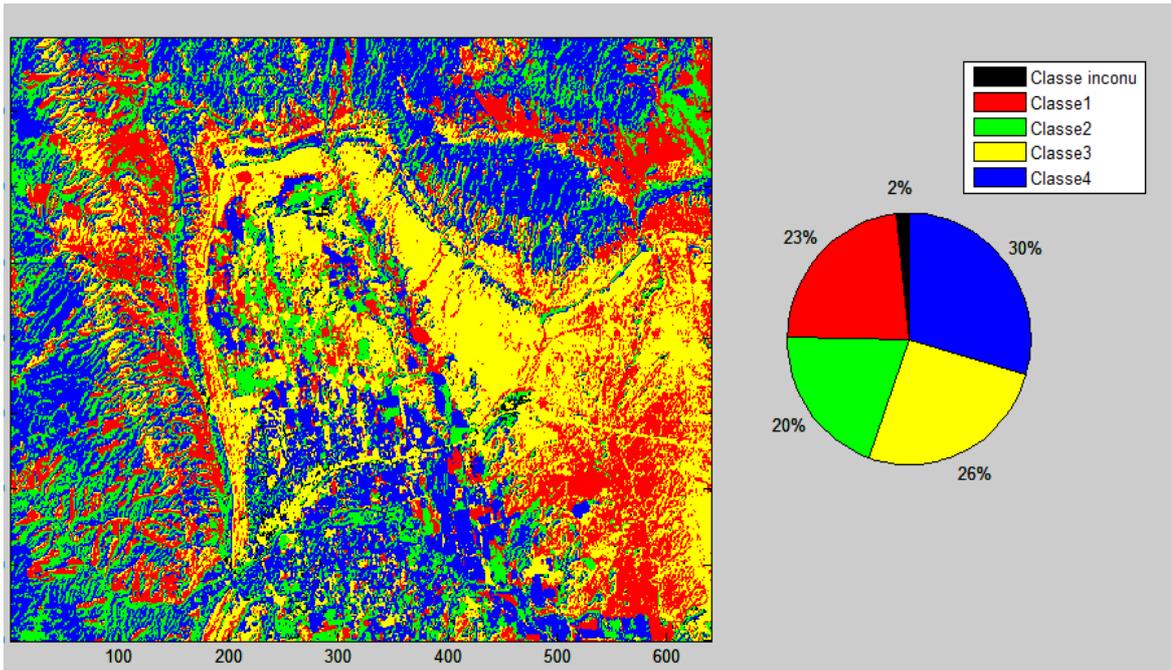


Figure 4.25 : Résultats de la classification par *SCS* (Canon City, Colorado,USA)

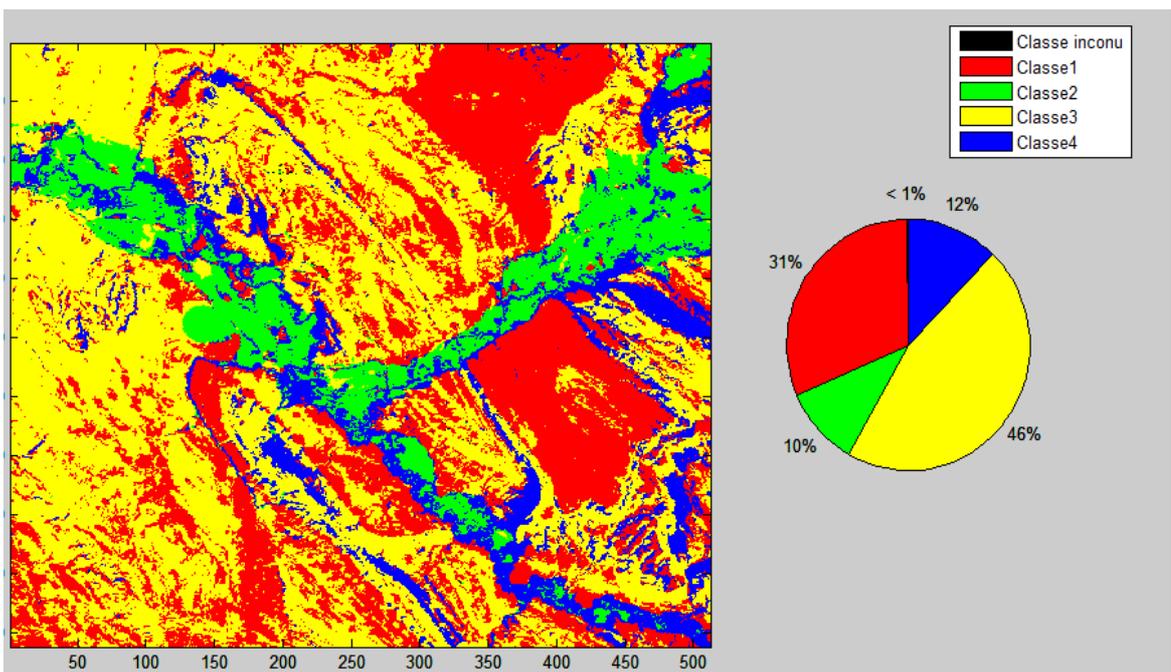


Figure 4.26 : Résultats de la classification par *SVS* (BIGORN BASIN .USA)

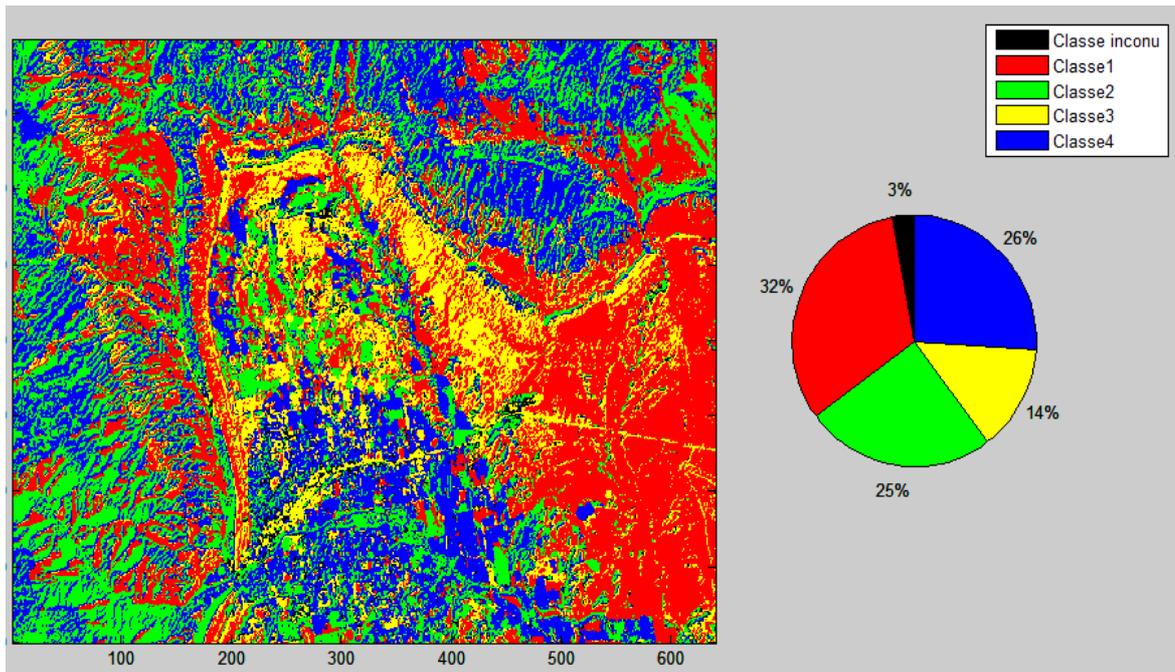


Figure 4.27 : Résultats de la classification par SVS (Canon City, Colorado, USA)

Comme nous l'avons déjà constaté précédemment, la méthode SDS ne donne pas des résultats satisfaisants comparativement aux autres méthodes qui permettent une meilleure discrimination des classes d'objets.

4.4.5 La fusion

Afin d'améliorer les résultats de la classification, nous avons choisi d'employer une stratégie de fusion aux niveaux de la mesure. Dans cette étape nous proposons de combiner les résultats de ces techniques pour obtenir de meilleurs résultats. Par conséquent, nous définissons un espace à trois dimensions où chaque axe correspond à une des mesures de similarité. Ensuite, nous définissons l'opérateur pour la fusion au niveau de la mesure.

4.4.5.1 Fusion par la distance euclidienne

Dans ce cas, nous employons les valeurs calculées pour chaque mesure. Par conséquent les valeurs s'étendent entre 0 et 1. Il est évident qu'un pixel de référence dans cet espace est le vecteur (1,1,1) ; d'où la distance euclidienne se définit comme :

$$E_d = \sqrt{(DN_{ss1} - 1)^2 + (DN_{ss2} - 1)^2 + (DN_{ss3} - 1)^2}$$

Puis, afin d'obtenir la carte finale, un seuil est appliqué sur ces distances. Les figures 5.13 (a) et (b) montrent les résultats pour les deux images.

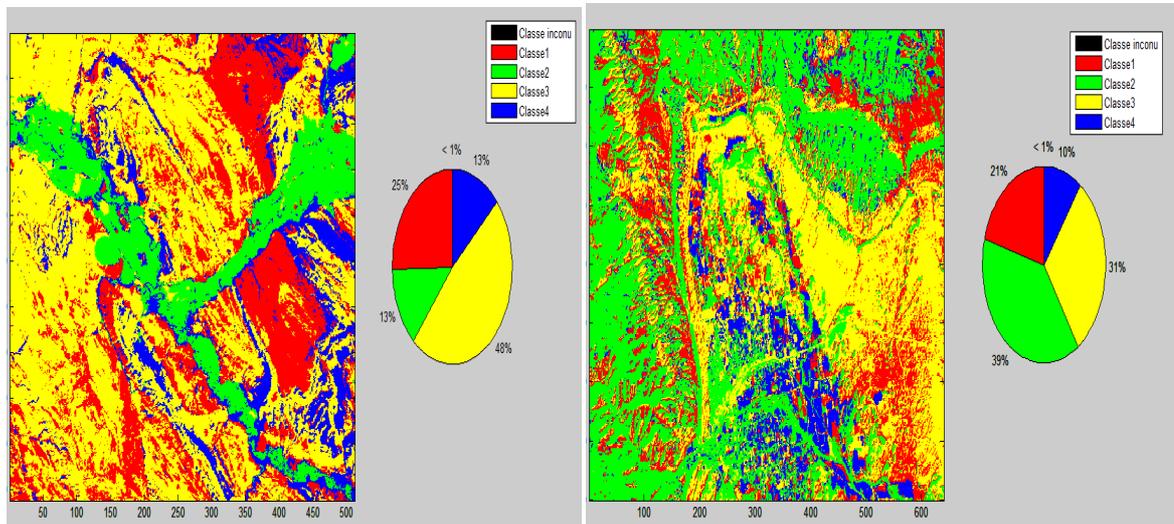


Figure 4.28: Résultats de la classification par la fusion des techniques SAM, SCS et SVS

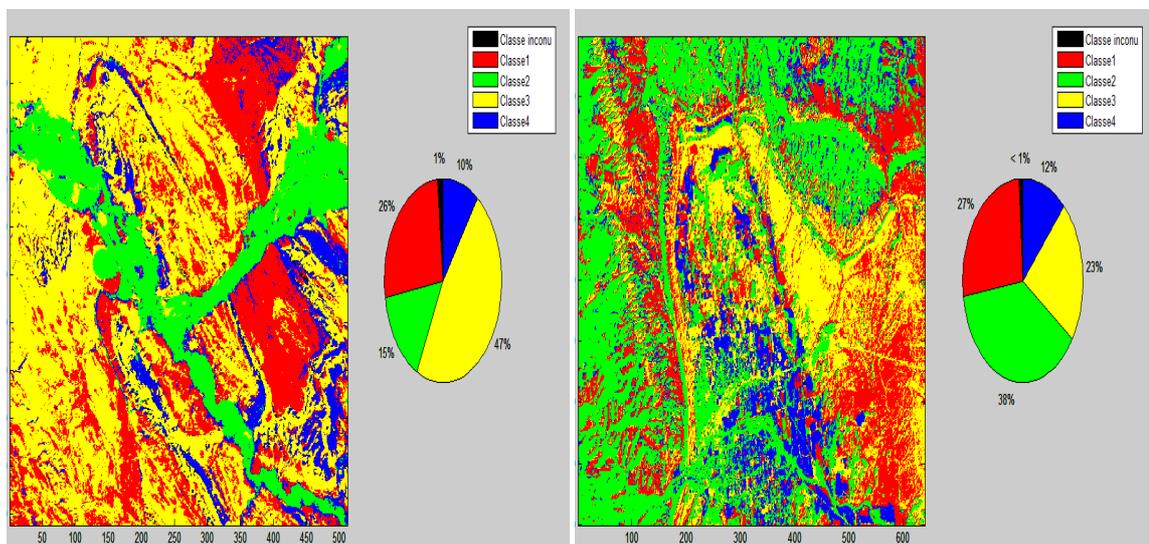


Figure 4.29 : Résultats de la classification par la fusion des techniques SDS, SCS et SVS

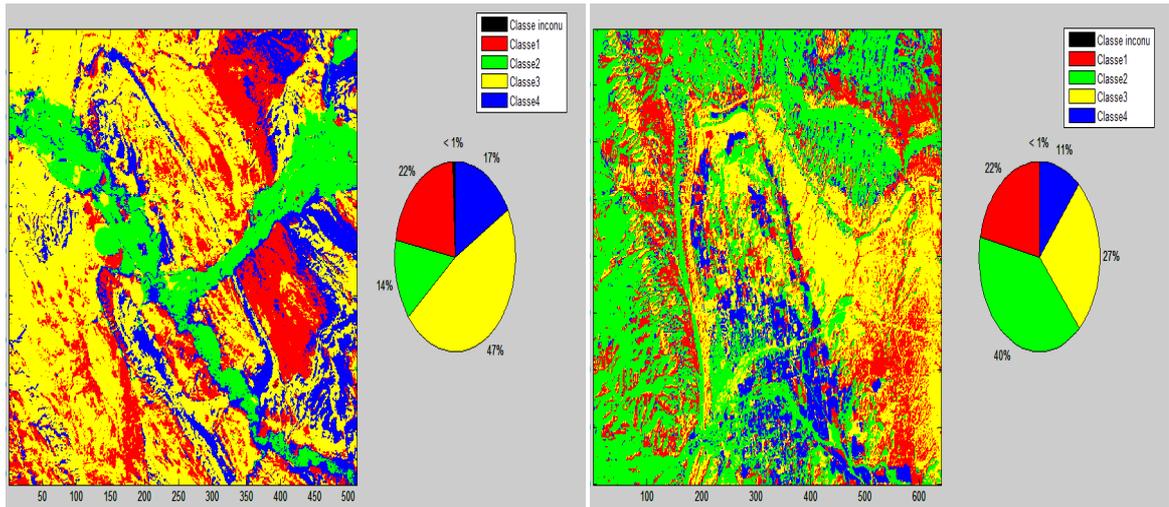


Figure 4.20 : Résultats de la classification par la fusion des techniques SAM, SCS et SDS

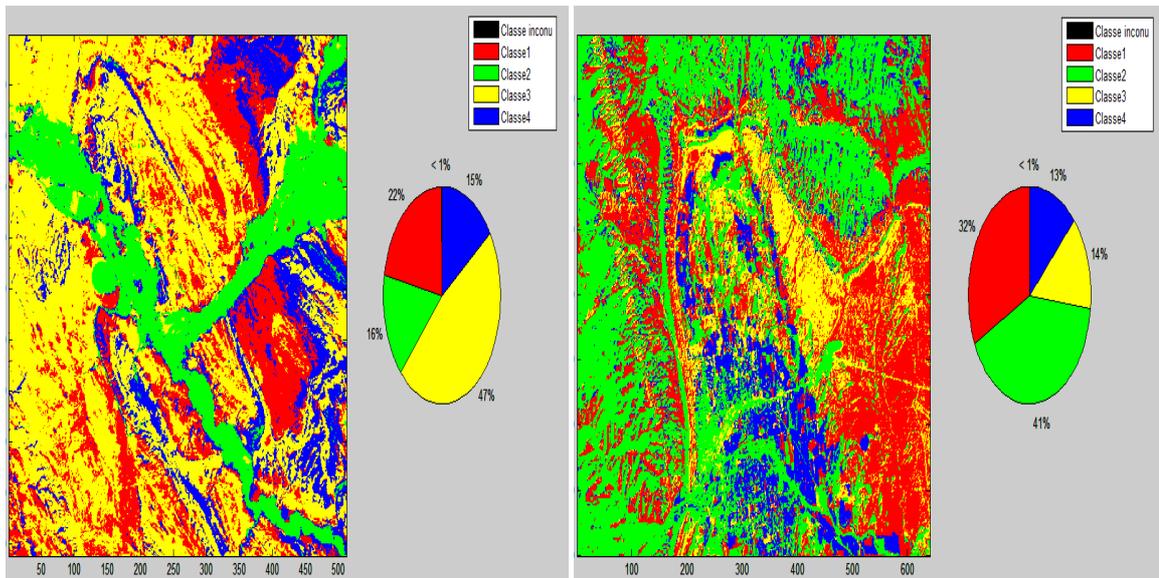


Figure 4.31 : Résultats de la classification par la fusion des techniques SAM, SCS et SVS

d'après ces résultats obtenus on constate que l'amélioration désirée par l'application de l'opérateur de fusion par la distance euclidienne paré visible, où le nombre des pixels inconnus est négligeable, ainsi que les différentes classes sont plus claires, surtout en ce qui concerne la fusion des méthodes SAM, SCS et SVS.

4.5 La classification par analyse en composantes indépendantes et VCA

Nous avons appliqué l'ACI en utilisant l'algorithme JADE. L'ACI est logiquement adaptée à notre problématique en considérant le modèle de mélange linéaire, de plus elle n'a pas besoin d'information a priori car elle fait partie des techniques de séparation

aveugle de source. Les étapes pratiques de cette mise en œuvre sont illustrées par l'organigramme suivant :

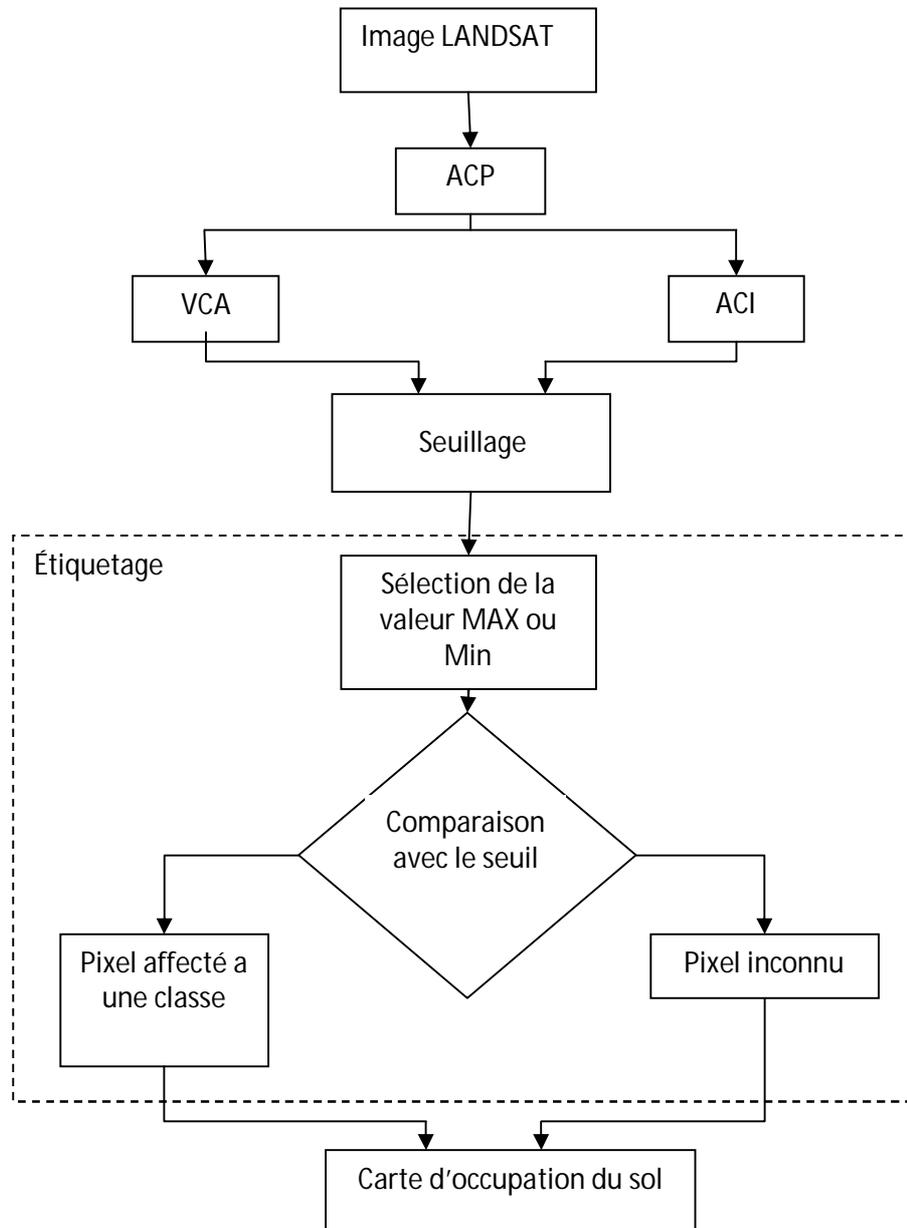


Figure 4.32 : organigramme des méthodes non supervisées

À la sortie de l'ACP on applique l'algorithme JADE pour générer l'ensemble des composantes indépendantes (CIs). L'algorithme génère autant de CIs que de CPs. Toutefois, l'examen visuel de ces CIs montre que seulement quelques-unes d'entre elles contiennent de l'information utile telle que des Ems. Les composantes indépendantes ainsi que leurs histogrammes correspondant sont présentés dans la figure 4.33.

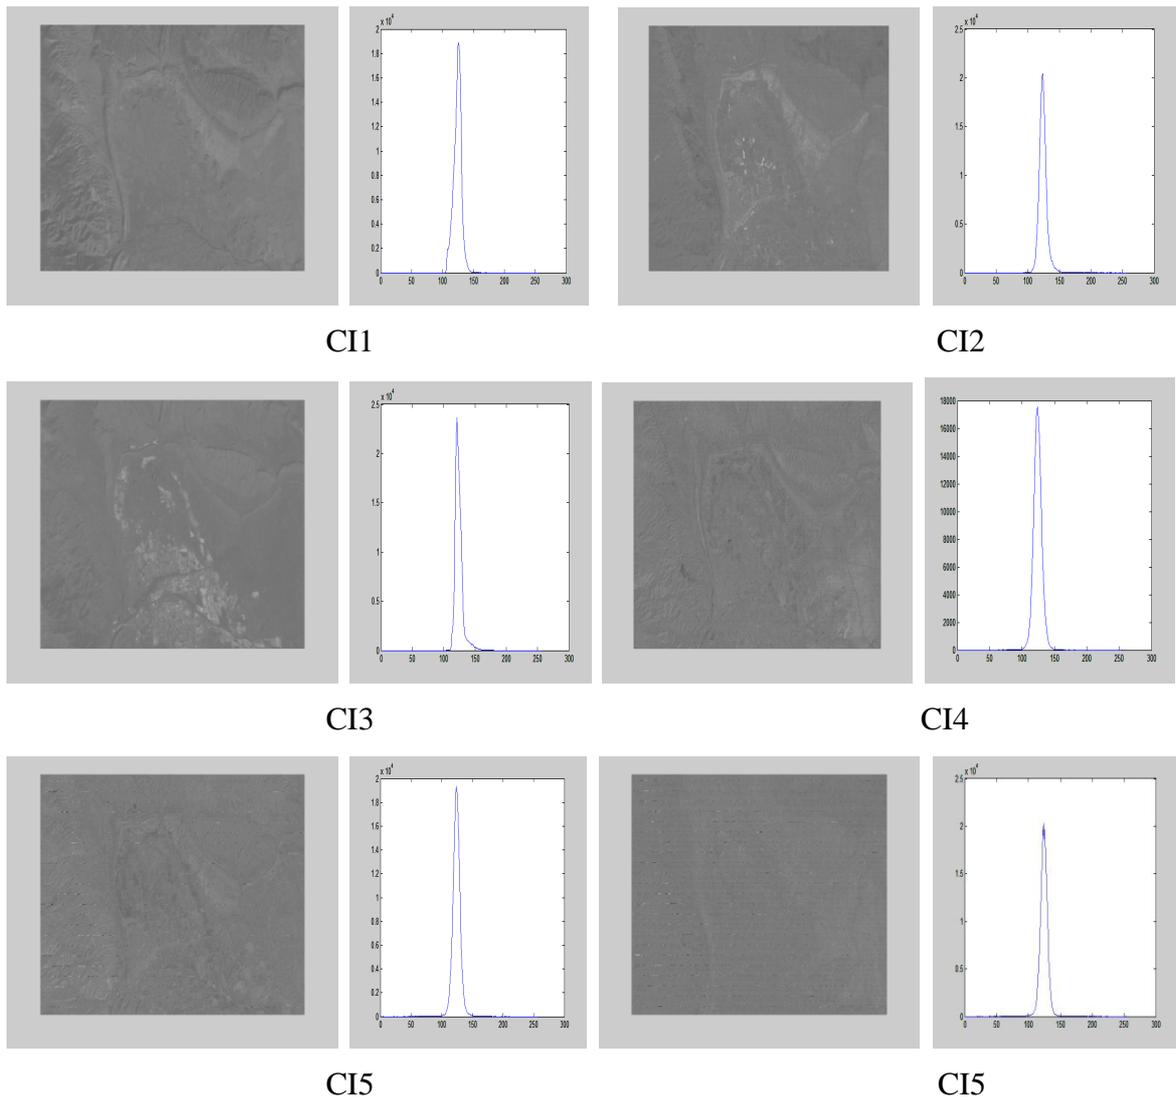


Figure 4.33: les composantes indépendantes (Canon City, Colorado,USA)

En considérant les histogrammes de chacune des CI, nous pouvons remarquer, par analyse visuelle, qu'une image reliée à un histogramme gaussien se caractérise par une absence d'informations significatives. Tandis qu'une image correspondant à un histogramme non gaussien contient des informations concernant un objet ou matériau.

Les composantes indépendantes en sortie de JADE sont classées selon leur importance par ordre décroissant. Ceci permet de ne sélectionner que les R premier CI, supposées les plus prioritaires et porteuses d'information.

En effet, chaque image est comme une carte d'indice de matériaux, dans laquelle les valeurs des pixels correspondent à l'abondance d'un matériau particulier. Nous avons suivi

la même procédure de seuillage et d'étiquetage qu'on a adopté pour les techniques de mise en correspondance ; les résultats sont illustrés dans les figure 4.34 et figure 4.35.

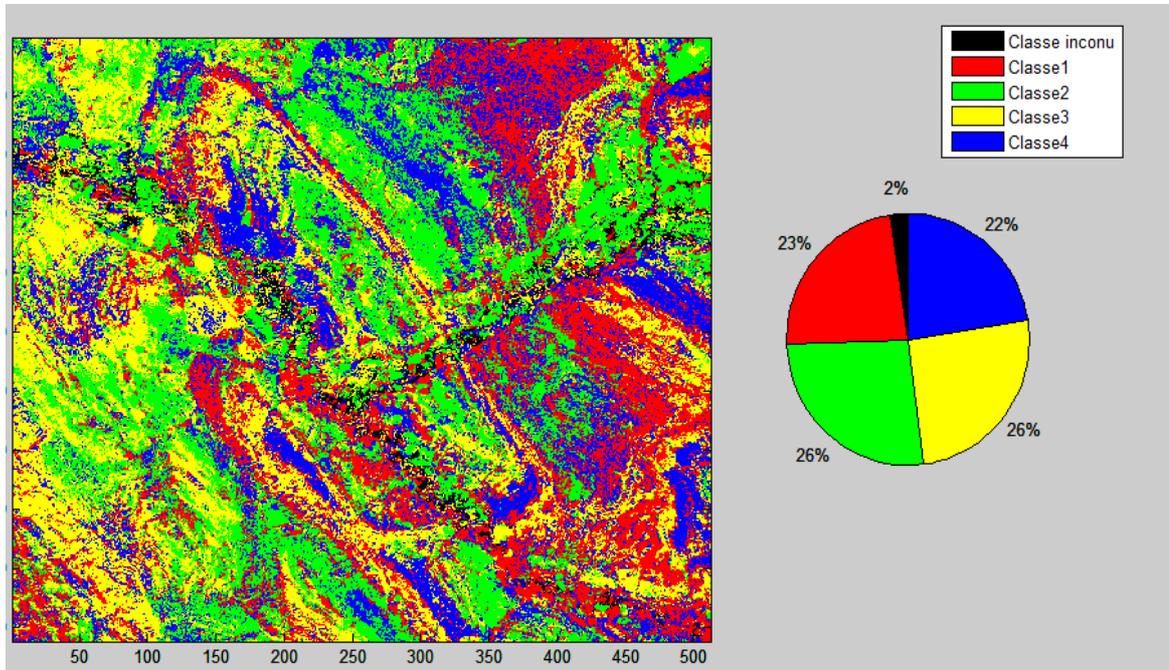


Figure.4.34 : Résultats de la classification par *ACI* (BIGORN BASIN .USA)

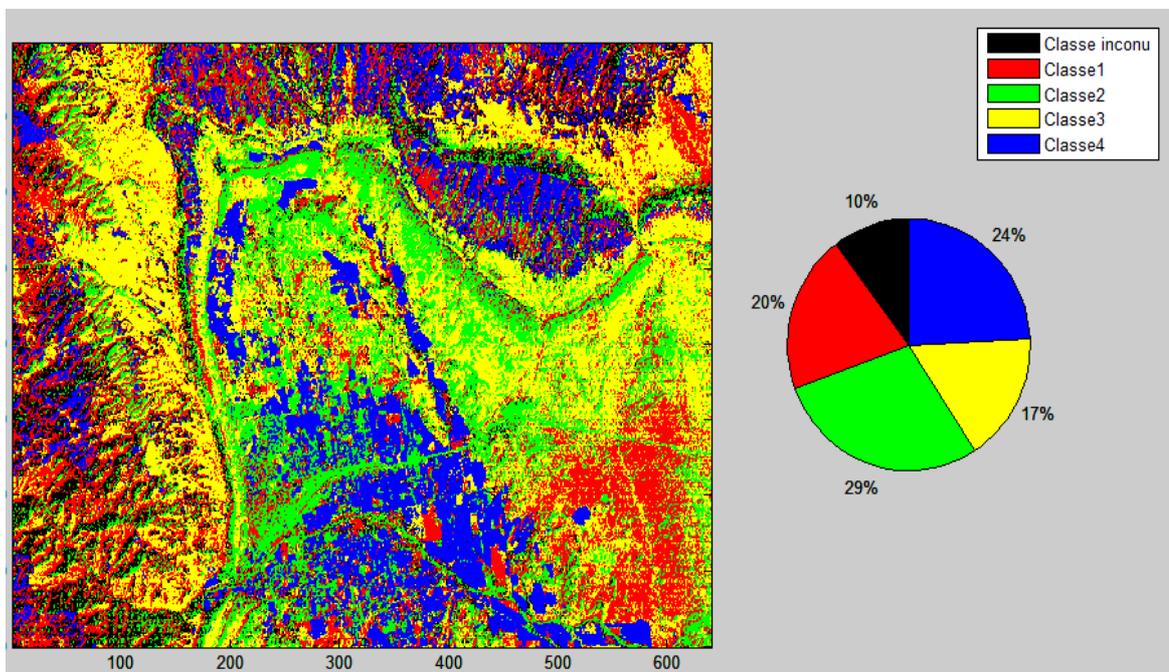


Figure.4.35 : Résultats de la classification par *ACI* (Canon City, Colorado.USA)

Nous avons utilisé l'algorithme VCA pour estimer les fractions d'abondance des différents EMs existants dans l'image. L'algorithme VCA est un algorithme non supervisé, il est fondé sur la définition géométrique des données multispectrales. Il exploite le fait que les Endmembers occupent les sommets du simplex.

VCA suppose la présence des pixels purs dans les données, et projetés de façon itérative sur la direction orthogonale à l'espace engendré par les EMs qui sont déjà déterminés. La nouvelle signature spectrale correspond à l'extrême de la projection, le reste des valeurs de projection correspondent à la fraction d'abondance de cette signature spectrale. La figure 4.36 montre les images des fractions d'abondance obtenues.

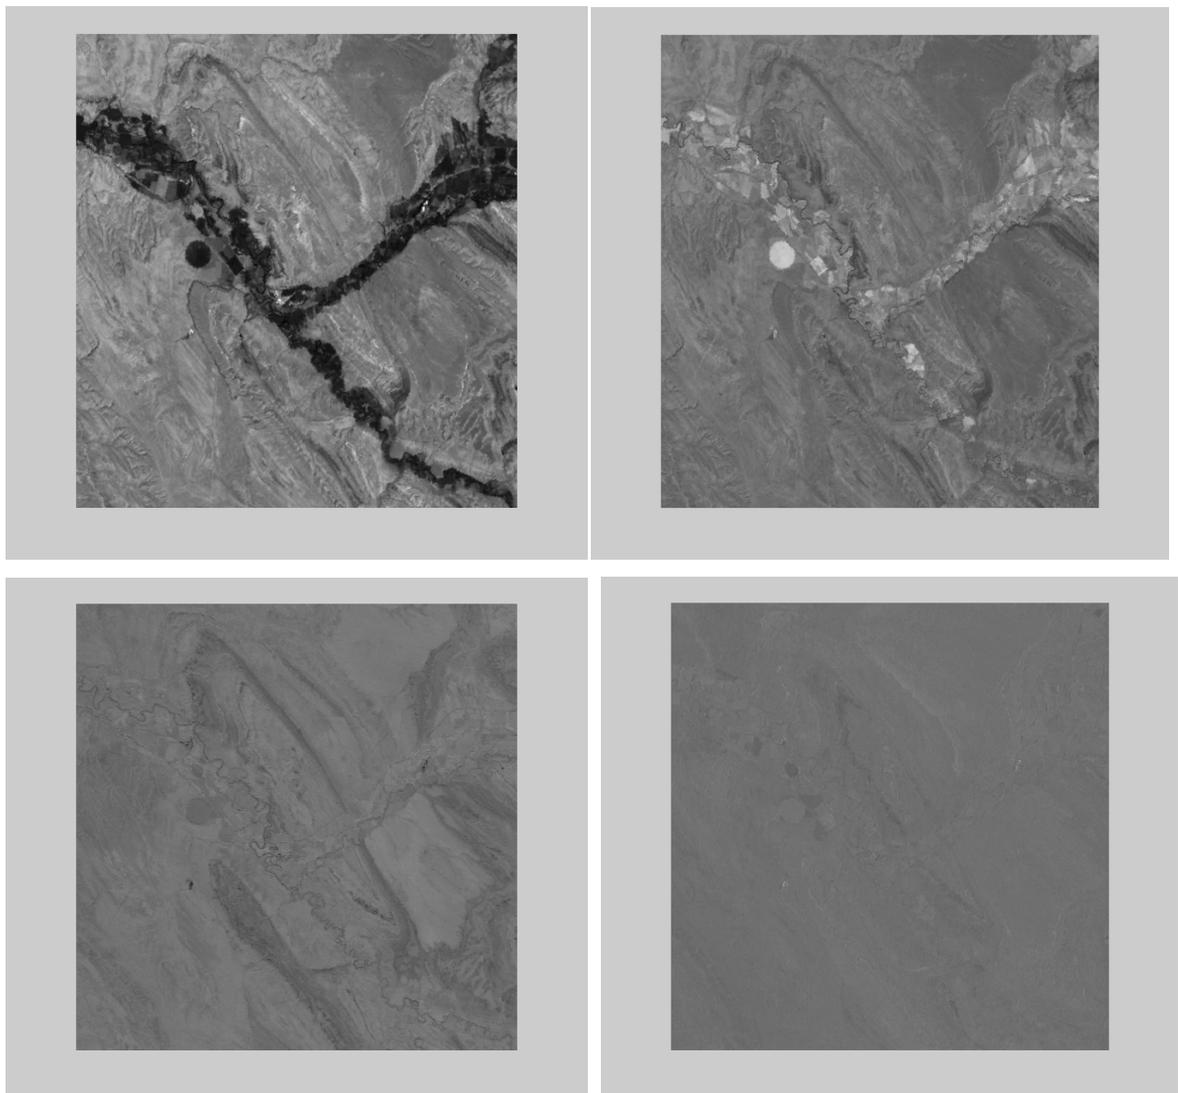


Figure.4.36: les images de fraction d'abondance obtenues par VCA
(BIGORN BASIN .USA)

De même que les images de similarité et les composantes indépendantes nous avons appliqué le seuillage d'Otsu pour calculer les seuils de décision ainsi que l'étiquetage. Les cartes d'occupation du sol sont illustrées sur les figures 4.37 et 4.38.

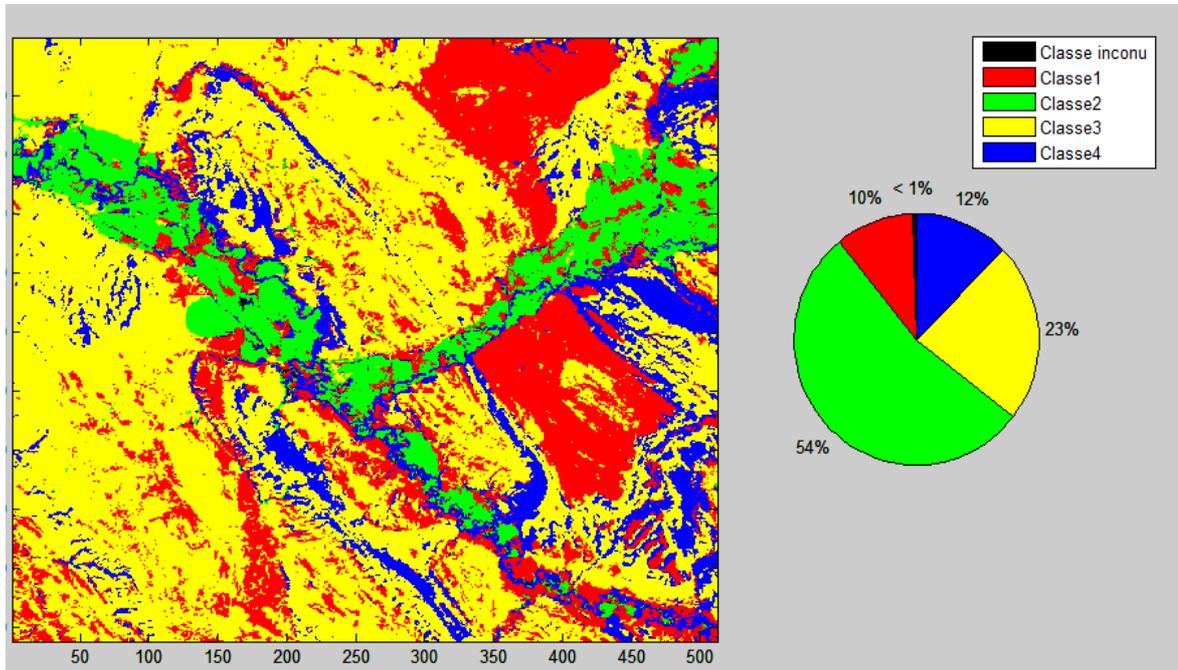


Figure 4.37 : Résultats de la classification par VCA (BIGORN BASIN .USA)

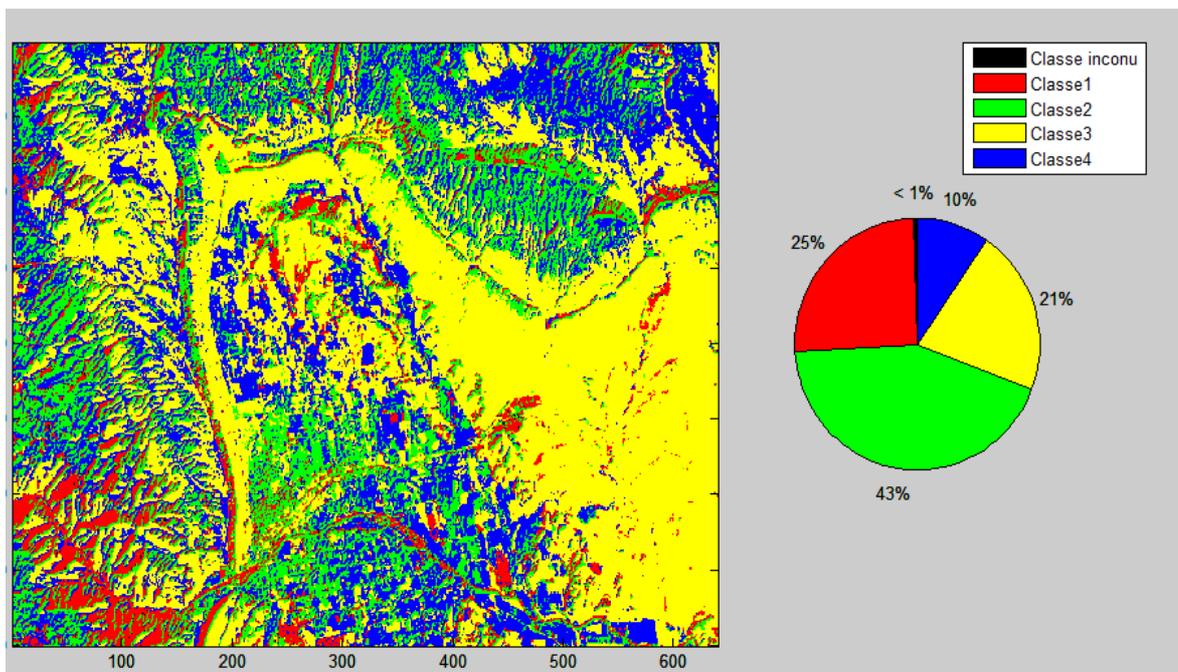


Figure 4.38 : Résultats de la classification par VCA (Canon City, Colorado.USA)

4.6 Évaluation statistique de la classification

Afin de réaliser une comparaison quantitative, de notre classification nous choisissons la classification SAM comme une référence, ensuite nous avons construit les matrices de confusion pour chaque technique.

Dans un premier temps nous avons comparé les résultats des méthodes SDS, SCS et SVS. Nous avons également vu l'effet de l'opérateur de la fusion par la distance euclidienne sur la classification, ensuite calculé les matrices de confusion pour les techniques ACI et VCA ainsi que les paramètres de précision.

4.7.1 La matrice de confusion

Une matrice de confusion ou tableau de contingence sert à évaluer la qualité d'une classification. Elle est obtenue en comparant les données classées avec des données de référence qui doivent être différentes de celles ayant servi à réaliser la classification.

Les *données de référence* sont acquises sur le terrain ou proviennent de photographies aériennes, de cartes thématiques... Pour permettre une comparaison, il faut qu'elles soient dans la même typologie que la classification. Le nombre de points de contrôle doit être suffisant et, si possible, de même importance dans chaque classe pour que la comparaison ait un sens. Si cela n'est pas possible, il faut prendre un plus grand nombre de points de contrôle pour les classes qui ont le plus d'importance thématique.

Discussion d'une matrice de confusion

La matrice de confusion se construit en mettant respectivement sur les lignes et sur les colonnes les données de référence et la classification. Ceci permet de calculer :

- la précision totale OA (Overall Accuracy) : nombre de pixels bien classés divisé par le nombre total d'individus.

- l'erreur d'excédents EC (Erreur de commission) : pourcentage de pixels d'une classe issue de la classification qui appartiennent, en fait à d'autres classes dans les données de référence.

- la précision pour l'utilisateur UA (User Accuracy) : pourcentage de pixels d'une classe issue de la classification correspondant à la même classe dans les données de référence. Elle est égale à « 100% - erreur d'excédents ».

- l'erreur de déficits EO (Erreur d'omission) : pourcentage de pixels d'une classe de référence affectés à d'autres classes par la classification.

- la précision pour le réalisateur PO (Producer Accuracy) : pourcentage de pixels d'une classe de référence affectés à la même classe par la classification. Elle est égale à « 100% - erreur de déficits ».

-coefficient de Kappa : Un statistique que mesure l'accord, hors de la chance, entre deux cartes (le résultat d'une classification et la carte de base).

$$kappa = \frac{N * \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (4.3)$$

Où r est le nombre de rangées dans la matrice de confusion, et x_{ii} est le nombre d'observations dans la rangée i et colonne i (sur le diagonal principal), x_{i+} est le total des observations dans rangée i, x_{+i} est le total des observations dans colonne i, et N est le total des observations incluse dans la matrice.

Notre choix a porté sur la classification par la méthode SAM comme une classification de la référence du fait, qu'elle prouve son efficacité et la fiabilité de ces résultats obtenus dans la littérature. Le tableau (4.5) regroupe les informations obtenues par SAM.

Classes	Pixels attribuées en pourcentage (%)	
	Image LANDSAT Canon City	Image LANDSAT BIGORN BASIN .USA
Classe 1	40.45	12.4
Classe 2	10.31	47.92
Classe 3	23.57	16.68
Classe 4	25.49	22.98
Classe inconnue	0.16	0

Tableau 4.5 : Pixels attribués par la technique SAM

De la première analyse visuelle faite sur ce tableau montre que la méthode SAM réussit à détecter la majorité des pixels, 99.98% pour l'image Canon City, et 100% pour l'image, qui sont apparemment des pixels de mélange.

L'évaluation d'une méthode est obtenue à partir des mesures de précision. Si ces mesures sont proches des valeurs idéales et que le nombre de pixels mal détectés est visiblement faible, cette méthode est relativement satisfaite.

Les tableaux 4.6 et 4.7 montrent les résultats obtenus par les mesures SDS, SCS et SVS.

Les techniques Les paramètres	SDS	SCS	SVS
la précision pour le réalisateur PA (%)	47.9	71.32	66.21
la précision pour l'utilisateur UA (%)	37.14	75.48	66.82
la précision totale OA (%)	44.79	90.6	79.08
coefficient Kappa	0.315	0.87	0.713

Tableau 4.6 : Les paramètres de précision pour les mesures de similarité (Canon City)

Les techniques Les paramètres	SDS	SCS	SVS
la précision pour le réalisateur PA (%)	70	60.42	63.5
la précision pour l'utilisateur UA (%)	26.48	62.12	53.5
la précision totale OA (%)	74.65	75.61	74.53
Coefficient Kappa	0.58	0.64	0.605

Tableau 4.7 : Les paramètres de précision pour les mesures de similarité (BIGORN BASIN)

D'après les résultats de précision, la carte obtenue par la technique SCS est la plus intéressante, les techniques SCS et SVS arrivent à détecter la majorité des pixels ainsi que les détails des différentes formes. Par contre la technique SDS n'a pas pu détecter de façon satisfaisante les pixels appartenant à la même classe en raison de l'influence de la topologie. Ceci peut être confirmé par la comparaison des résultats obtenus à partir des deux images. Dans l'image Canon City qui présente des reliefs, les paramètres de précision sont faibles par rapport à ceux obtenus par l'image Bigorn Basin qui ne présente que du plat (74.65% contre 44.8% pour la précision globale et 0.584 contre 0.315 pour le coefficient Kappa). En considérant les résultats de SVS, nous observons que les paramètres de précision sont un peu moins bons que ceux obtenus par SCS mais la carte obtenue par SVS semble visiblement bonne et satisfaite.

De la même façon, nous avons calculé les paramètres de précision pour les cartes obtenues par les techniques de fusion. Les résultats sont présentés sur les tableaux (4.8 et 4.9).

Les techniques Les paramètres	Fusion 1 SAM-SCS-SVS	Fusion 2 SDS-SCS-SVS	Fusion 3 SAM-SCS-SDS	Fusion4 SAM-SCS-SDS
la précision pour le réalisateur PA (%)	67.3	69.01	73.8	63.31
la précision pour l'utilisateur UA (%)	62.8	63.29	57.12	55.89
la précision totale OA (%)	83.34	84.96	83.92	77.2
Coefficient Kappa	0.74	0.767	0.743	0.64

Tableau 4.8 : Les paramètres de précision pour la technique de fusion (Canon City)

Les techniques Les paramètres	Fusion 1 SAM-SCS-SVS	Fusion 2 SDS-SCS-SVS	Fusion 3 SAM-SCS-SDS	Fusion 4 SAM-SCS-SDS
la précision pour le réalisateur PA (%)	73.16	72.46	65.23	69.6
la précision pour l'utilisateur UA (%)	75.3	74.95	66.45	70.29
la précision totale OA (%)	93.46	93.26	82.65	86.05
Coefficient Kappa	0.908	0.905	0.75	0.8

Tableau 4.9 : Les paramètres de précision pour la technique de fusion (BIGORN BASIN)

Comme les résultats de la fusion sont visuellement meilleurs qu'avec les méthodes primaires, les résultats quantitatifs prouvent également que la fusion peut améliorer les cartes en sortie.

Nous avons calculé les résultats de précision pour les cartes obtenues par l'ACI et VCA. Les résultats sont illustrés dans les tableaux 4.10 et 4.11.

Les techniques Les paramètres	ACI	VCA
la précision pour le réalisateur PA (%)	32.63	47.48
la précision pour l'utilisateur UA (%)	26.74	36.13
la précision totale OA (%)	40.39	66
Coefficient Kappa	0.21	0.485

Tableau 4.10 : Les paramètres de précision pour ACI et VCA (Canon City)

Les techniques	ACI	VCA
Les paramètres		
la précision pour le réalisateur PA (%)	32.97	29.78
la précision pour l'utilisateur UA (%)	43.04	36.51
la précision totale OA (%)	40.09	40.9
Coefficient Kappa	0.3	0.228

Tableau 4.11 : Les paramètres de précision pour ACI et VCA (BIGORN BASIN)

En ce qui concerne l'ACI, théoriquement elle est bien adaptée à notre problème de mélange linéaire. Par contre la carte est visuellement un peu moins bonne avec beaucoup de bruit. On observe la présence d'un nombre considérable des pixels inconnus, relativement aux cartes obtenues par d'autres techniques, une explication possible est la présence de mélange. En fait lorsque la taille de l'objet par rapport à la résolution spatiale est petite, le mélange est plus important, cela veut dire que la linéarité ou non linéarité du mélange influence la sensibilité de l'ACI.

En considérant les résultats obtenus par VCA, bien qu'ils soient visuellement bons les résultats quantitatifs ne sont pas satisfaisants. Cela s'explique probablement de la façon de démixage effectué par la VCA où les signatures spectrales détectées par VCA sont différentes à celles détecté par la N-FINDER.

4.7 Amélioration des performances du système

Après évaluation des différentes techniques, nous avons essayé d'améliorer les résultats obtenus. Pour cela, nous avons établi deux algorithmes hybrides combinant les techniques de mesure spectrales avec les techniques de classification par ACI et VCA. L'organigramme de la figure 4.37 montre les étapes suivies.

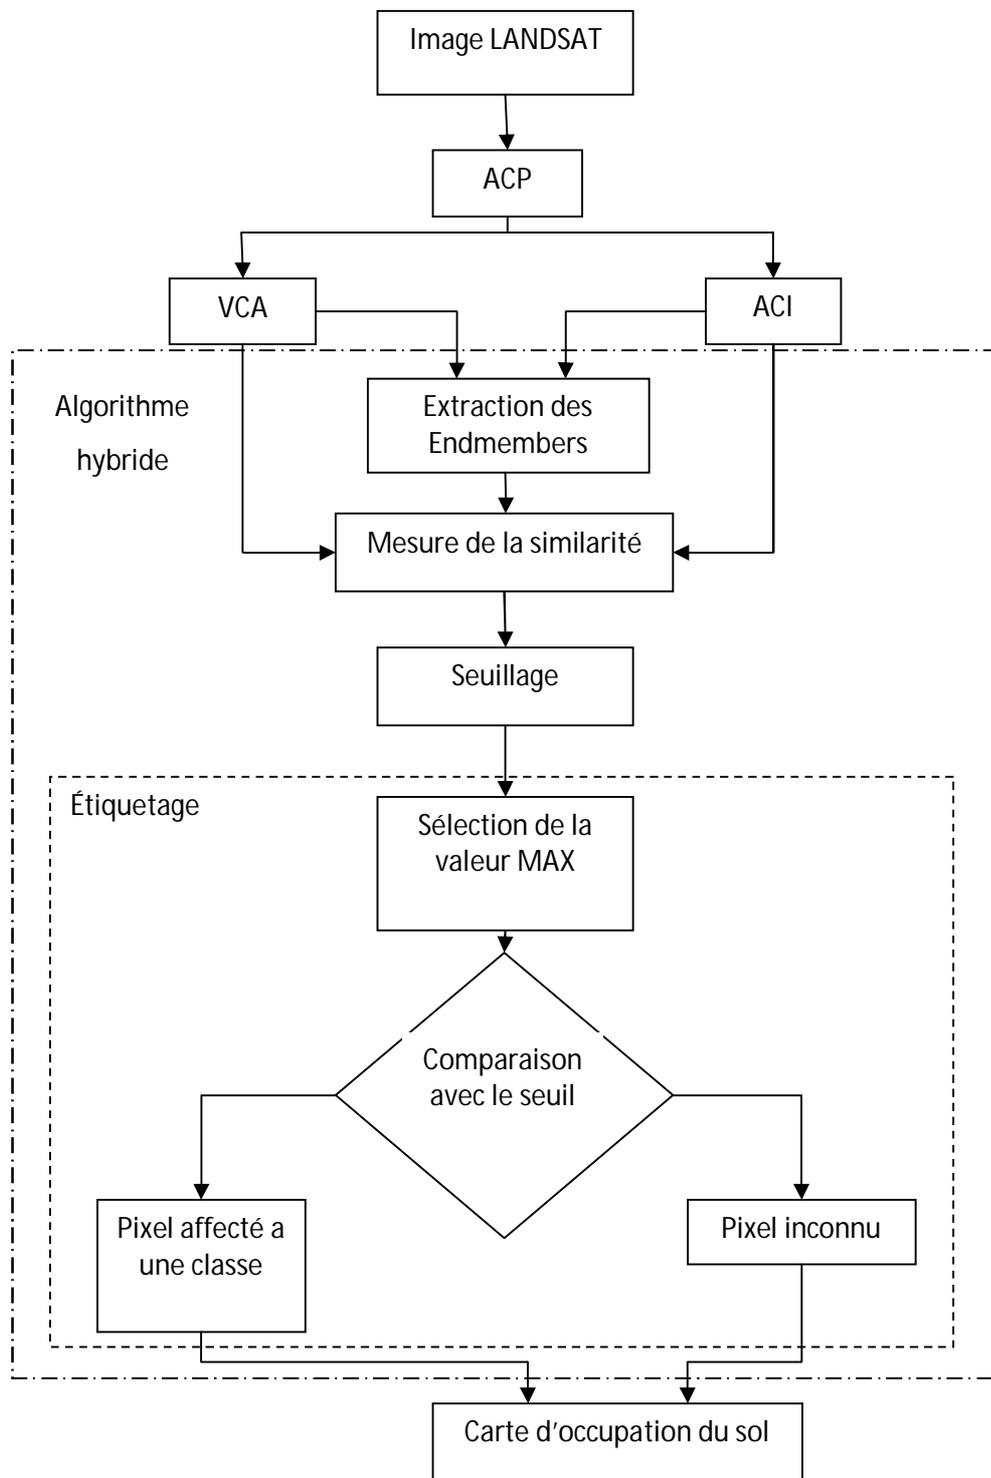


Figure 4.39 : Organigramme de la coopération des méthodes

Nous avons appliqué l'algorithme hybride sur les images. Les cartes obtenues sont illustrées sur les figures suivantes.

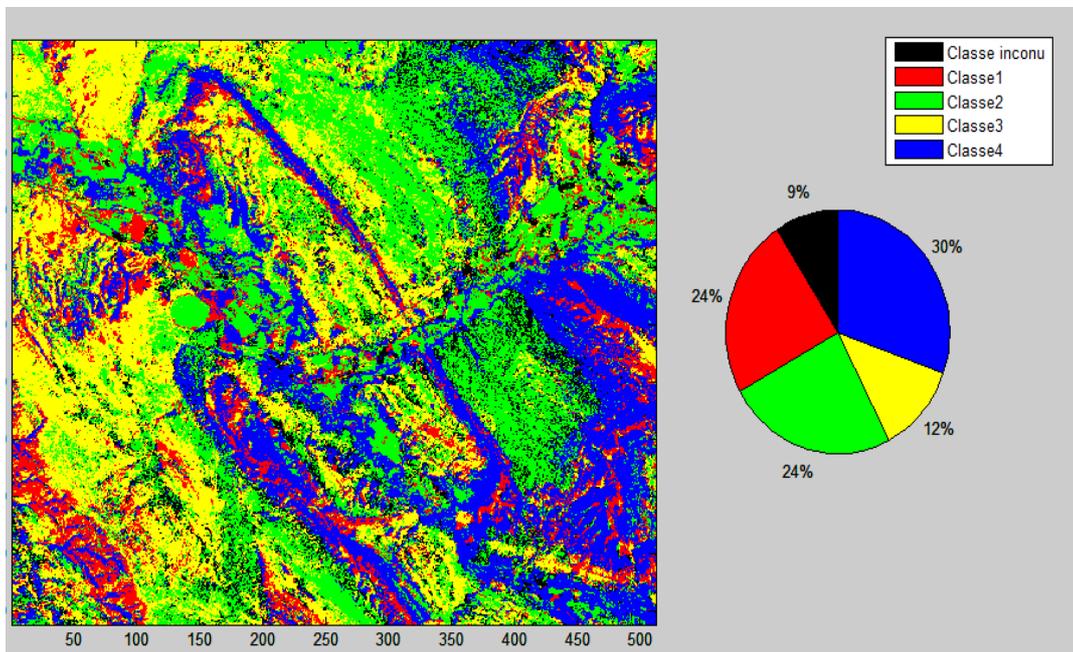
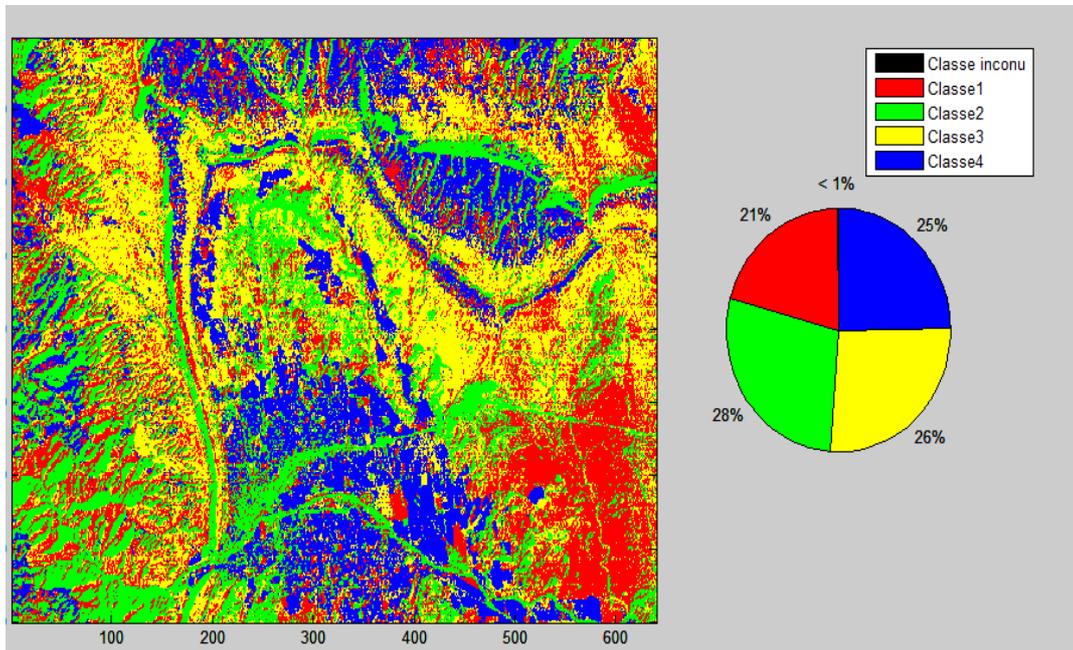


Figure 4.40 : Résultats de la classification par la méthode hybride ACI-SAM

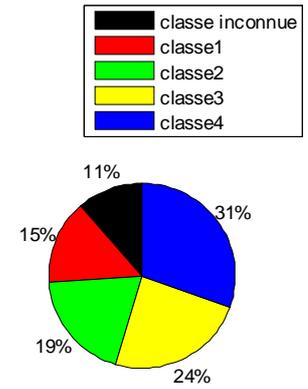
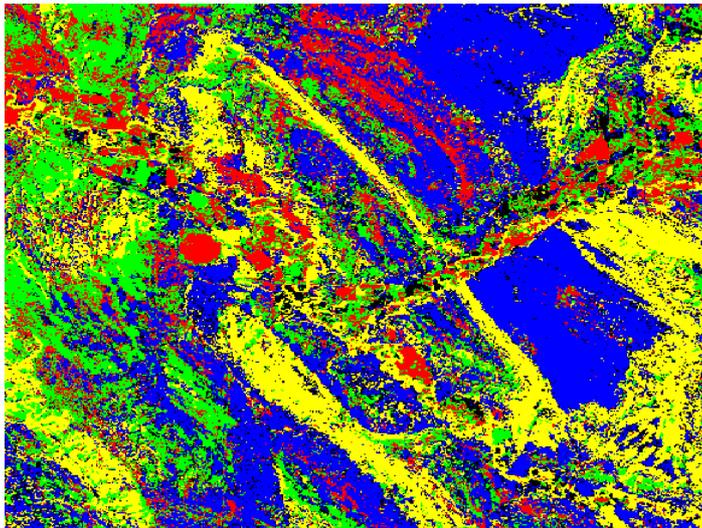
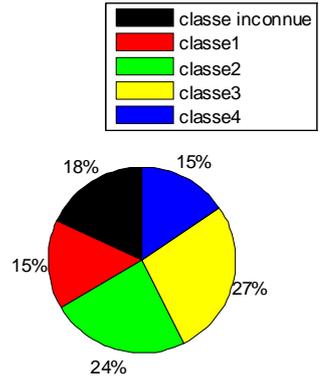
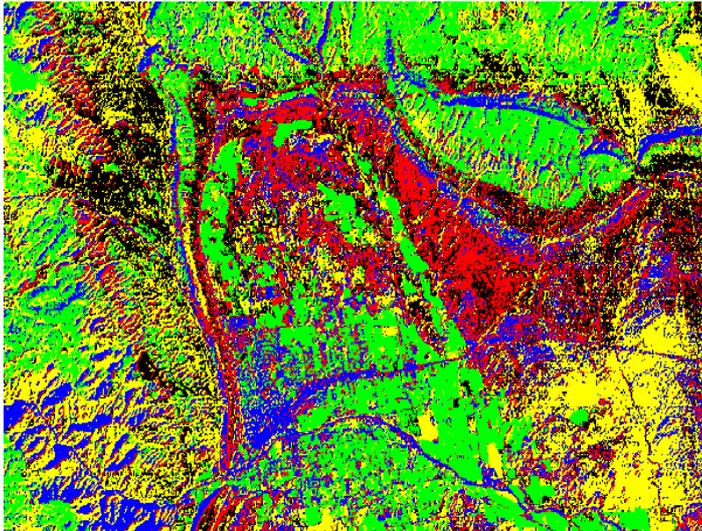


Figure 4.41 : Résultats de la classification par la méthode hybride ACI - SCS

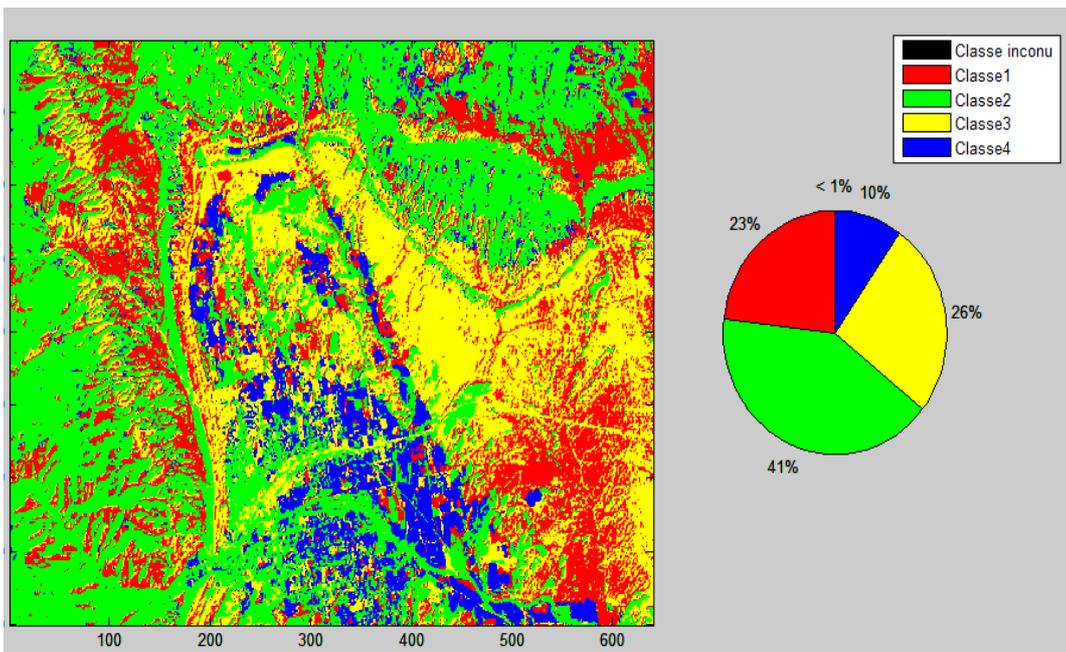
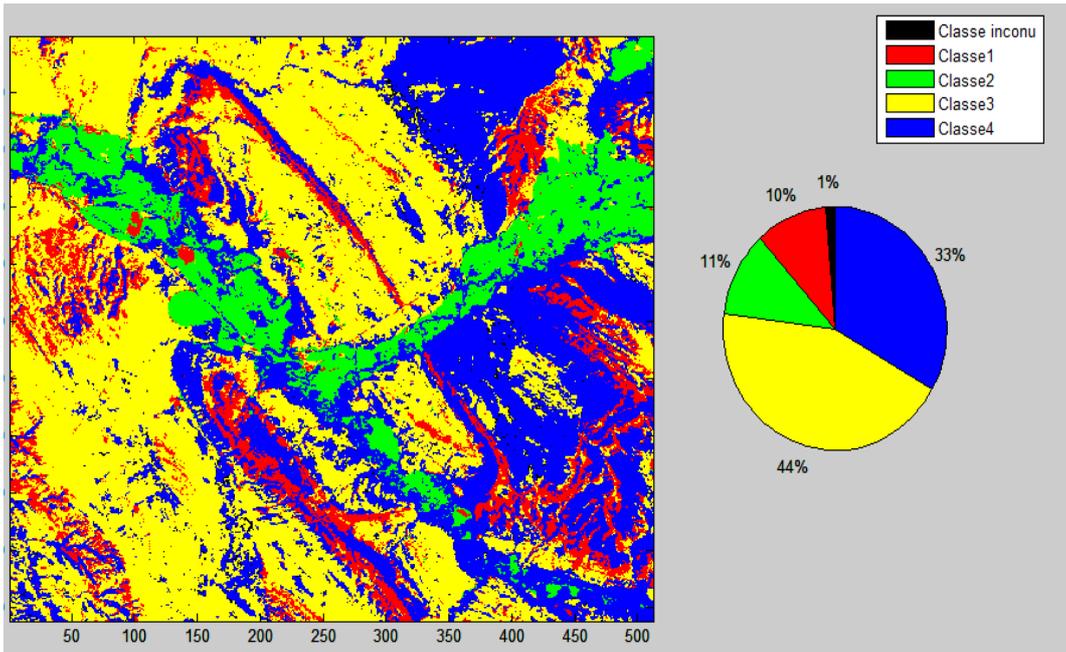


Figure.4.42 : Résultats de la classification par la méthode hybride VCA - SAM

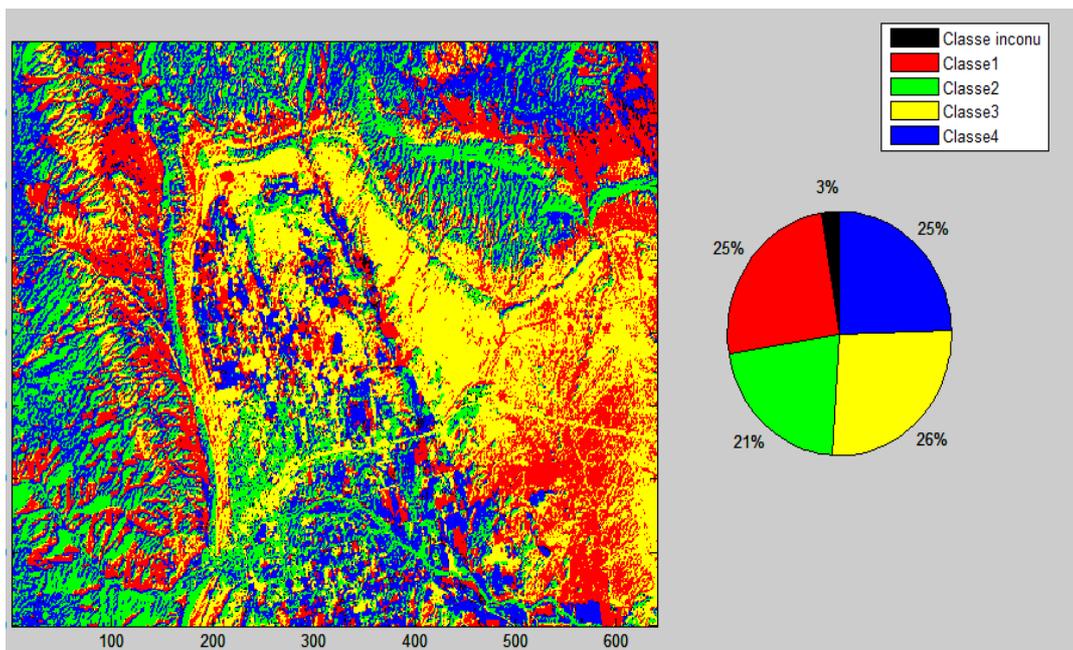
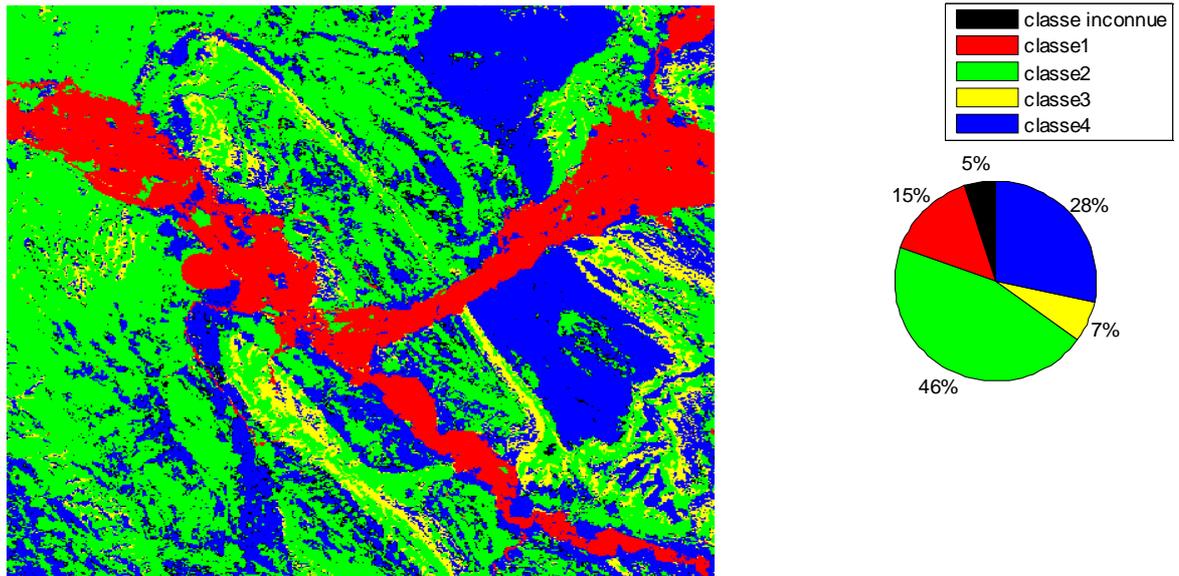


Figure.4.43 : Résultats de la classification par la méthode hybride VCA - SCS

En considérant les cartes obtenues par les algorithmes hybrides ACI-SAM et ACI-SCS, on constate une nette amélioration de la qualité :

- dispersion quasi-totale du bruit ;
- plus de détails entre classes ;
- diminution remarquable des pixels inconnus

Les résultats ainsi obtenus par les algorithmes VCA-SAM et VCA-SCS présentent une bonne amélioration comparativement aux autres méthodes. Les cartes obtenues sont proches aux références.

Les paramètres de précision des algorithmes coopératifs sont calculés et illustrés dans les tableaux suivants :

Les techniques Les paramètres	Canon City		BIGORN BASIN	
	ACI-SAM	ACI-SCS	ACI-SAM	ACI-SCS
la précision pour le réalisateur PA (%)	41.78	35.68	35.7	34.07
la précision pour l'utilisateur UA (%)	45.6	42.04	38.51	44.75
la précision totale OA (%)	51.75	44.38	45.26	45.05
Coefficient Kappa	0.352	0.26	0.24	0.21

Tableau 4.12 Les paramètres de précision par coopération ACI-SAM et ACI-SCS
(Canon City.USA)

Les techniques Les paramètres	Canon City		BIGORN BASIN	
	VCA-SAM	VCA-SCS	VCA-SAM	VCA-SCS
la précision pour le réalisateur PA (%)	100	74.34	100	72.63
la précision pour l'utilisateur UA (%)	100	74.52	100	91.97
la précision totale OA (%)	100	93.02	100	84.97
Coefficient Kappa	1	0.902	1	0.786

Tableau 4.13 Les paramètres de précision par coopération VCA-SAM et VCA-SCS
(BIGORN BASIN)

Bien que l'amélioration est claire au niveau des cartes obtenues par les algorithmes ACI-SAM et ACI-SCS, les paramètres de précision ne confirment pas cette amélioration. Cela peut être expliqué par le fait qu'on a utilisé la classification par la technique SAM comme une référence. Par contre les résultats obtenus par VCA-SAM et VCA-SCS sont positifs ce qui conduit à dire que la coopération des méthodes réussit à améliorer les résultats de la classification.

4. 8 Conclusion

Dans ce chapitre, nous avons décrit nos expériences sur la classification d'images satellitaires par les différentes techniques citées dans le chapitre 3. D'après les résultats obtenus, nous constatons que les méthodes qui reposent sur les mesures de similarité sont plus précises que les méthodes exploitant l'ACI et le VCA. Une amélioration sensible a été apportée par la coopération des méthodes VCA-SAM et VCA-SCS; la précision totale dépasse les 80%.

CONCLUSION GENERALE

La disponibilité des images satellitaires constitue potentiellement un très grand apport pour la cartographie des ressources naturelles et de l'état de surface terrestre.

Conscients des difficultés liées à la qualité d'information sous-jacente, de l'inadéquation des méthodes classiques de traitement d'images et au coût d'acquisition élevé de données lithologiques et des mesures de terrain ou en laboratoire, nous sentons le besoin d'établir des stratégies d'analyse et d'interprétation adaptées à la nature des données. La richesse de l'information spectrale ouvre la voie à une cartographie à l'échelle subpixellaire par des techniques de démixage spectral.

Dans le but d'obtenir une carte d'occupation du sol précise, nous avons utilisé trois techniques de démixage ; une technique supervisée qui repose sur les mesures de similarité et deux techniques non supervisées.

Dans l'approche supervisée, nous avons commencé par la détection des signatures spectrales des pixels purs qui existent, puis nous avons appliqué les mesures de similarité. Nous avons montré la possibilité d'exploiter une procédure de démixage spectral basée sur des mesures de similarité. La similarité de corrélation spectrale a permis d'obtenir une carte d'occupation du sol précise.

Pour les techniques non supervisées, la classification des images LANDSAT par l'analyse en composantes indépendantes (ACI) n'a pas généré de bons résultats. Dans sa forme standard, l'ACI ne convient pas très bien à l'objectif de la classification et de la cartographie des matériaux. La raison de cet inconvénient pourrait en être les contraintes qui n'ont pas été prises en compte. Une autre limitation de l'ACI est la condition nécessaire pour les données et le modèle de mélange. En fait, certains effets comme la linéarité du modèle de mélange restent encore à évaluer et à examiner.

A partir des résultats obtenus, nous avons tenté d'améliorer la classification. Nous avons mis au point une nouvelle méthode basée sur la coopération des techniques non supervisées (ACI et VCA), et des mesures de similarité spectrales. La précision de la classification obtenue atteste de la robustesse apportée par la combinaison des techniques.

Le travail ainsi réalisé ne représente qu'une initiation à la concrétisation des efforts basés sur le model linéaire, et dans la perspective de mieux cernés les problèmes liés à ce domaine, des études feront l'objet par des modèles non linéaires qui prendra en considération les différent types de mélange tel que le mélange intime et le mélange enduit, se qui aboutira à des nouveaux techniques ou méthodes plus complexes à savoir les méthodes probabilistes non linéaire et l'ACI non linéaire où bien, les methodes basées sur l'intelligence artificielle comme la logique flou et les réseaux de neurones.

APPENDICE

LISTE DES SYMBOLES ET DES ABREVIATIONS

ACI	: Analyse En Composantes Indépendantes
ACP	: Analyse En Composantes Principales
ADF	: Analyse Discriminante De Fisher
AF	: Analyse Factorielle
AMEE	: Automated Morphological Endmember Extraction
CI	: Composante Indépendante
CNES	: Centre National D'études Spatiales
CP	: Composante Principale
DSU	: Derivative Spectral Unmixing
EMs	: Les Endmembers
Endmember	: Signature Spectrale (Membre Extreme)
ESSA	: Environmental Science Services Administration
FAST-ICA	: Fast Independant Component Analysis (Analyse en composantes indépendante rapide)
HFC	: Harsanyi-Fanand-Chang
HRG	: Haute Résolution Géométrique
HRV	: Haute Résolution Visible
HRVIR	: Haute Résolution Visible Et Infrarouge
JADE	: Jouint Aproximate Diagonalization Of Eyen Matrices
LANDSAT	: Land Satellite
MESMA	: Multiple Endmember Spectral Mixture Analysis
ML	: Maximum Libelihood
MMS	: Scanners Multi Spectraux
MML	: Model De Mélange Linéaire
MNA	: Modèles Numériques D'altitude
N-FINDER	: Number Finder
NWHFC	: Whitened HFC
OSP	: Orthogonal Subspace Projection
PPI	: Pixel Purity Index
REM	: Rayonnement Électromagnétique
SAM	: Spectral Angle Mapper

SAS	: Séparation Aveugle Des Sources
SCS	: Similarité par Corrélacion Spectrale
SDS	: Similarité par Distance Spectrale
SOBI	: Second Order Blind Identification
SP	:Subspace Projection
SPOT	: Satellite Pour l'Observation de la Terre
SVO	: Singular Value Decomposition
SVS	: Similarité par Valeur Spectrale
TM	: Thematic Mapper
VCA	: Vertex Component Analysis
VD	: Virtuel Dimensunality
VMESMA	: Variable Multiple Endmember Spectral Mixture

RÉFÉRENCES

- [1] X. MEURET : L'évaluation des techniques de classification en télédétection pour l'étude de l'occupation du sol en Irlande. Mémoire de travail de fin d'études, École Supérieure des Géomètres et Topographes, 1 Boulevard Pythagore - 72000 LE MANS, juillet 2008
- [2] centre canadien de télédétection : Notions fondamentales de télédétection, cour tutoriel, 2007.
- [3] I. Benhadj : Observation spatiale de l'irrigation d'agrosystèmes semi-arides et Gestion durable de la ressource en eau en plaine de Marrakech. Université Toulouse III, 2008.
- [4] L. AIT BRAHIM et M. MANSOUR : les technologies spatiales un outil pour la gestion des catastrophes naturelles et environnementales, L'Organisation islamique pour l'Education, les Sciences et la Culture – ISESCO ,Avenue des F.A.R. - Hay Riad, B.P. 2275 - C.P. 10104 Rabat, Royaume du Maroc,2009.
- [5] S.CHITROUB : Analyse en Composantes Indépendantes d'images Multibandes : faisabilité et Perspectives. Revue Télédétection, 2007, vol. 7, n° 1-2-3-4, p. 541-555.
- [6] C.Kergomard : la télédétection aérospatiale : une introduction, Ecole Normale Supérieure Paris, 2007.
- [7] <http://ac-besan.fr>
- [8] M.C. Girard : COURS DE TELEDETECTION, institut national agronomique paris-grignon département agronomie environnement, cour, Octobre 2000.
- [9] G.ROCHON, F.BONN et G.LADOUCEUR : Cours de télédétection appliquée. Projet ACDI/SheI. Université Laval, Québec, document interne, 1982.
- [10] Y.TIMOULALI et A.MEDOURI : Principes, méthodes et applications de la télédétection. Organisation islamique pour l'Education, les Sciences et la Culture – ISESCO, 2009.
- [11] <http://e-cours.univ-paris1.fr>.
- [12] Centre de Ressources pour Enseignants de la NASA: Les Orbites des Satellites,” <http://science-edu.larc.nasa.gov>
- [13] <http://fr.wikipedia.org>

- [14] <http://eoeu.belspo.be>
- [15] BONN et ROCHON G : Précis de télédétection, vol. 1 Principes et méthodes. Universités Francophones, Presses de l'Université du Québec, pp. 298-388,1993.
- [16] S. Homayouni : Caractérisation des Scènes Urbaines par Analyse des Images Hyperspectrales. Thèse doctorat Signal et Images. École Nationale Supérieure des Télécommunications de Paris, Décembre 2005.
- [17] Z. Ben Rabah : Demixage spectral d'images hyperspectrales et fusion possibiliste des connaissances : application à l'érosion hydrique. Thèse de Doctorat Traitement du Signal et Télécommunication. Département : ITI, Télécom Bretagne, septembre 2011.
- [18] F.D. Meer et S.M. Jong: Imaging Spectrometry. Remote Sensing and Digital Image Processing. Kluwer Academic Publishers, 2001.
- [19] Leung, C. T., and Siu, W. C.: A general contrast function based blindsource separation method for convolutively mixed independent sources. Signal Processing, Elsevier, 87, pp. 107–123, 2007.
- [20] O. Eches : Méthodes Bayésiennes pour le démixage d'images hyperspectrales. Thèse doctorat Signal, Image, Acoustique et Optimisation. Institut National Polytechnique de Toulouse (INP de Toulouse), Octobre 2010.
- [21] Roberts, D. A., Batista, G. T., Pereira, J. L. G., Waller, E. K. & Nelson, B.: Change identification using multitemporal spectral mixture analysis: applications in eastern Amazonia. In Remote Sensing Change Detection, pp. 137.161, 1998.
- [22] F. A. Kruse, A. B. Lefkoff, and J. B. Dietz: Expert system based mineral mapping in northern Death Valley, California/Nevada using the AVIRIS, Remote Sens. Environ., vol. 44, pp. 309–335, 1993.
- [23] J. Zhang and A. Sanchez: Derivative Spectral Unmixing of Hyperspectral Data Applied to Mixtures of Lichen and Rock IEEE TGRS, 42(9), 1934-1940, 2004.
- [24] García-Haro, F. J. Sommer, S. Kemper, T.: Variable multiple endmember spectral mixture analysis (VMESMA) , IJRS, V. 26, Number 10, pp. 2135-2162(28), 2005.
- [25] R.H. Yuhas, A.F.H. Goetz, and J.W. Boardman: Discrimination among semi-arid landscape endmembers using the spectral angle mapper (sam) algorithm. Summaries of the Third Annual JPL Airborne Geoscience Workshop, 92-14 :147-149, 1992.
- [26] M. CHIKHAOUI, F. BONN, A. MERZOUK, B. LACAZE et A. Mohamed MEJJATI: Cartographie de la dégradation des sols à l'aide des approches du spectral angle mapper et des indices spectraux en utilisant des données aster, Revue Télédétection, 2007, vol. 7, n° 1-2-3-4, p. 343-357, mai 2007.

- [27] M.S.Karoui, Y.Develle, S.Hosseini, A.Ouamri : Traitement des données hyperspectrales par des méthodes de séparation aveugle des sources : faisabilité et perspectives. Journées d'animation scientifique (JAS09) de l'AUF Alger, novembre 2009.
- [28] F. FLITTI : Techniques de réduction de données et analyse d'images multispectrales astronomiques par arbres de Markov. Thèse de doctorat, Traitement d'images et vision par ordinateur, Université Louis Pasteur - Strasbourg I, décembre 2005.
- [29] R. Solofoarisoa : Analyse en composantes principales d'une image multispectrales de télédétection, communication, 1998.
- [30] J. NASCIMENTO :Unsupervised hyperspectral unmixing. Thèse de doctorat, Instituto Superior Técnica, Universidade Técnica de Lisboa, Dec. 2006.
- [31] J. Wang and C.-I Chang :Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery. IEEE Transactions on Geoscience and Remote Sensing, 44, no.9, 2006.
- [32] A. Belouchrani, K. A. Meraim, J.F. Cardoso, E. Moulines : A blind source separation technique using second-order statistics. IEEE Signal Proc., 45, 434-444, 1997.
- [33] E.BAHRI, D. HABOUDANE, A.BANNARI, F. BONN et L. CHILLASSE : Essai de cartographie des espèces forestières dominantes dans le moyen atlas (Maroc) à l'aide des données ASTER, article, université de Québec, Canada, Meknès, Maroc, 2007.
- [34] J. Martínez, M. Pérez, A. Plaza, L. Aguilar, C. Cantero and J. Plaza: Endmember extraction algorithms from hyperspectral images, publication, Computer Science Department, University of Extremadura, Cáceres, Spain,2006.
- [35] Q. Du, N. Raksuntorn, H. Younan, L. King: Variants of N-FINDR Algorithm for Endmember Extraction,Department of Electrical and Computer Engineering, Mississippi State University, MS 39762, USA,2008.
- [36] Q.Du, N. Raksuntorn: On the Performance of Endmember Extraction Algorithms for Hypersepctral Image Analysis, publication, Department of Electrical and Computer Engineering, Mississippi State University, MS 39762, USA,2008.
- [37] S. MATHIEU : Aide à la détermination de faciès pédopaysagers à partir de données satellitaires, thèse doctorat, université de Paris 7, 1994.

[38] O. ECHES, N. DOBIGEON, J. TOURNERET : Analyse d'images hyperspectrales à l'aide d'un modèle de mélange de spectres aléatoires, publication Université de Toulouse, IRIT/INP-ENSEEIH/TESA, 2009.

[39] K.SOUDANI : Cour Télédétection ECO II (Version 1.2).Cour. Université Paris-Sud XI- 91405 Orsay. – mars 2005