

Stéphane BAZEILLE
Paul HEMAR
Baptiste MOUGEL
Fabien NG FOK

Maîtrise IUP Génie informatique
Université de La Rochelle

Rapport d'Image Numérique



Examineur : Pierre LOONIS
Enseignant : Jean-Marc OGIER
Années : 2003-2004

Sommaire :

Introduction	3
I- Transformation de Karhunen-Loeve et Analyses en Composantes Principales : Application à la compression d'images multispectrales.	4
1- Objectif.....	4
2- Théorie	4
a- Analyse en Composantes Principales.....	4
b- Transformation de Karhunen-Loeve	5
3- Pratique.....	6
4- L'algorithme.....	8
a- Application.....	9
b- Résultats	10
II- Classification Bayesienne	12
1- Introduction à la classification Bayesienne.....	12
2- Théorie	12
a- La décision Bayesienne.....	13
b- La fonction discriminante :	13
3- Algorithme	14
4- Analyse du cas des images Palni.....	15
a- Observation des imagerie fournies par l'expert.....	17
b- Analyse des résultats après classification par la méthode de BAYES.....	17
c- Ce que l'on retient de l'étude.....	19
d- Version améliorée de classification.....	20
5- Conclusion sur la Classification Bayesienne	21
Conclusion.....	22

Introduction

Dans le cadre notre enseignement en image numérique nous allons vous présenter un rapport exposant deux méthodes concernant l'analyse et le traitement des images. Ces deux méthodes sont l'ACP ou Analyse en Composantes Principales et la Classification Bayésienne.

L'analyse en composante est une méthode statistique permettant de déterminer des paramètres de classification ou d'améliorer le rendu d'une image. Dans une seconde partie nous étudierons la classification bayésienne qui contrairement à l'ACP permet de distinguer les différentes classes d'une image.

Dans la présentation de ces deux méthodes nous développerons d'abord la partie théorique suivi de son illustration par une application à un exemple. Pour ces deux exemples nous travaillerons sur quatre images satellite LANDSAT représentant une région géographique terrestre. Ces images sont nommés Palni 1 2 .3 et 4 et seront présentées dans la première partie de ce rapport.

I- Transformation de Karhunen-Loeve et Analyses en Composantes Principales : Application à la compression d'images multispectrales.

1- Objectif

Nous disposons d'une scène d'image multispectrale constituée d'enregistrements de quatre capteurs spectraux, d'un satellite d'observation (Landsat). Les images de la scène ont des redondances d'informations. On souhaiterait effectuer un traitement donné sur une partie des données. L'analyse en composantes principales et la transformation de Karhunen-Loeve sont des techniques utilisées pour réduire cette redondance en conservant le maximum d'information.

2- Théorie

a- Analyse en Composantes Principales

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'analyse en composantes principales (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. 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 nième et dernière composante principale. Les pertes d'informations diminuent d'une étape à la suivante.

Les différentes opérations de l'ACP sont :

- le calcul des matrices de covariance et de corrélation de l'image multispectrale, ce sont des matrices carrées dont la dimension est égale au nombre des canaux spectraux de l'image;
- le calcul des valeurs et vecteurs propres de la matrice de covariance;
- le calcul des composantes principales de l'image multispectrale; le nombre des composantes est au plus égal à celui des canaux spectraux, quatre dans notre cas.

Pour ces calculs, on pose variables suivantes X_1, X_2, X_3 et X_4 représentant les N pixels en niveaux de gris des quatre images obtenu par les capteurs spectraux. Les moyennes de ces variables sont calculées suivant $i=1, 2, 3, 4$

$$\overline{X_i} = \frac{1}{N} \cdot \sum_{j=1}^N X_i^j$$

Ces moyennes servent à calculer les covariances et les corrélations entre deux variables. La covariance entre les variables X_i et X_j où $i, j=1, 2, 3, 4$ est :

$$Cov(X_i, X_j) = \frac{1}{N} \cdot \sum_{k=1}^N [(X_i^k - \overline{X_i}) \cdot (X_j^k - \overline{X_j})]$$

La matrice de covariance Q constitué des covariances entre les variables où $i, j=1, 2, 3, 4$:

$$Q = \{Cov(X_i, X_j)\}_{4 \times 4}$$

On a la variance de chaque variable par le calcul suivant :

$$\sigma_i^2 = \frac{1}{N} \cdot \sum_{j=1}^N \left[(X_i^j - \bar{X}_i)^2 \right] \text{ Avec } i=1, 2, 3, 4.$$

On obtient les écarts type de chaque variable en prenant la racine carré des variances. Ces écarts type interviennent dans le calcul des corrélations entre deux variables. La corrélation entre les variables X_i et X_j où $i, j=1, 2, 3, 4$ est :

$$\text{Cor}(X_i, X_j) = \frac{1}{N} \cdot \sum_{k=1}^N \left[\frac{(X_i^k - \bar{X}_i)}{\sigma_i} \cdot \frac{(X_j^k - \bar{X}_j)}{\sigma_j} \right]$$

La matrice de corrélation S constitué des corrélations entre les variables où $i, j=1, 2, 3, 4$:

$$S = \{ \text{Cor}(X_i, X_j) \}_{4 \times 4}$$

Le polynôme caractéristique de la matrice de covariance nous permet le calcul des valeurs propres λ_i . Les valeurs propres sont les valeurs qui vérifient :

$$\det(Q - \lambda \cdot Id) = 0$$

Dans notre cas, on obtient quatre valeurs propres $\lambda_1, \lambda_2, \lambda_3$ et λ_4 associées à quatre vecteurs propres V_1, V_2, V_3 et V_4 tels que :

$$Q \times V_i = \lambda_i \cdot V_i \text{ Avec } i=1, 2, 3, 4.$$

A partir de ces vecteurs propres, on peut obtenir les composantes principales Y_i avec $i=1, \dots, I$ et $I \leq 4$; on a :

$$Y_i^k = \sum_{j=1}^N [V_k^j \cdot (X_i^j - \bar{X}_i)]$$

b- Transformation de Karhunen-Loeve

La transformée de Karhunen-Loeve vise à concentrer le maximum d'informations statistiques en terme de variance sur un même axe. L'étalement des valeurs statistiques sur l'axe rassemblant le maximum d'informations en terme de variance contribue à accentuer la capacité de discrimination des objets géographiques. Les informations statistiques contenues sur les autres axes de la transformée de Karhunen-Loeve constituent de nouvelles informations statistiques qui par leur contenus inédits peuvent enrichir la connaissance du territoire étudié.

Soient N pixels représentant un bloc (vecteur) X . On modélise la corrélation entre ces pixels par la matrice de covariance.

$$R_{N \times N} = E \left[(X - \bar{X}) \cdot (X - \bar{X})^T \right]_{N \times N}$$

L'élément (i,j) de la matrice est la covariance des pixels X_i et X_j . On le note σ_{ij}^2 .

$$R = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \dots & \sigma_{1N}^2 \\ \sigma_{21}^2 & \sigma_{22}^2 & \dots & \sigma_{2N}^2 \\ \dots & \dots & \dots & \dots \\ \sigma_{N1}^2 & \sigma_{N21}^2 & \dots & \sigma_{NN}^2 \end{bmatrix}$$

Si on suppose que la covariance ne dépend que la distance entre les pixels $\sigma_{ij} = f(|i - j|)$, et que l'on normalise R se met sous la forme :

$$R = \begin{bmatrix} 1 & \rho_1 & \cdots & \rho_{N-1} \\ \rho_1 & 1 & \cdots & \rho_{N-2} \\ \cdots & \cdots & \cdots & \cdots \\ \rho_{N-1} & \cdots & \rho_1 & 1 \end{bmatrix}$$

Les vecteurs propres de la matrice R forment une base de fonctions de décomposition. On cherche les vecteurs propres de cette matrice, et on note A la matrice de transformation.
 $c = A \times X$

La matrice de covariance de c est

$$R' = A \times R \times A^T$$

Elle est diagonale.

$$R' = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \lambda_N \end{bmatrix}$$

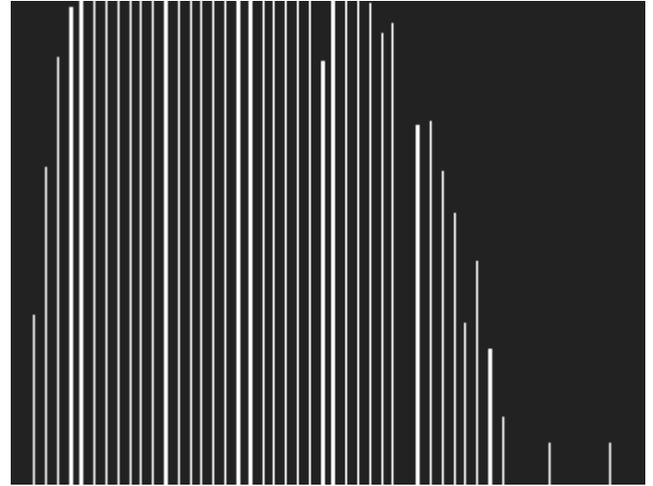
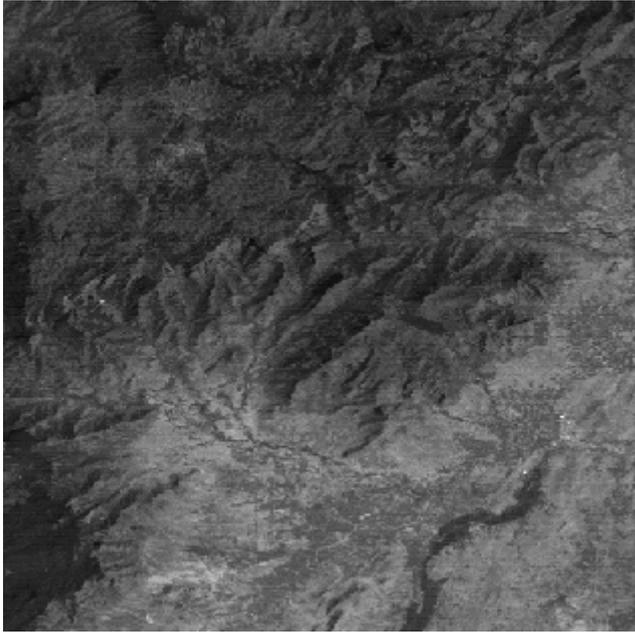
Si on trie les valeurs propres de la matrice par ordre décroissant, on obtient :
 – des coefficients totalement décorrélés (la matrice de covariance est diagonale)
 – une forte concentration d'énergie dans les premiers coefficients
 Transformation optimale.

3- Pratique

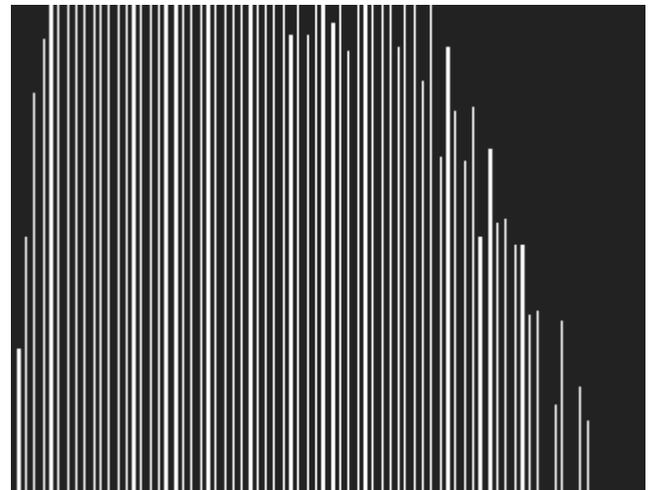
On cherche ici à obtenir quatre nouveaux clichés satellite en effectuant une analyse en composantes principales sur quatre clichés satellite initiaux ayant chacun des caractéristiques de contraste et de netteté différentes. Le premier cliché obtenu sera plus net et contrasté que le second, de même que le second sera plus net et contrasté que le troisième et ainsi de suite.

Voici les quatre clichés satellite initiaux ainsi que les histogrammes de niveaux de gris correspondant :

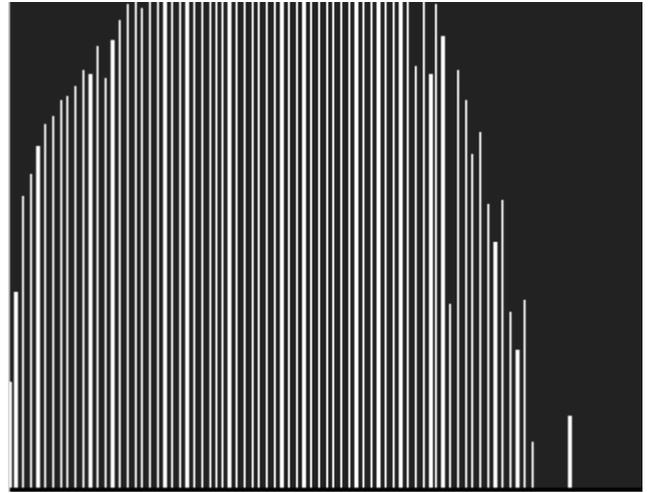
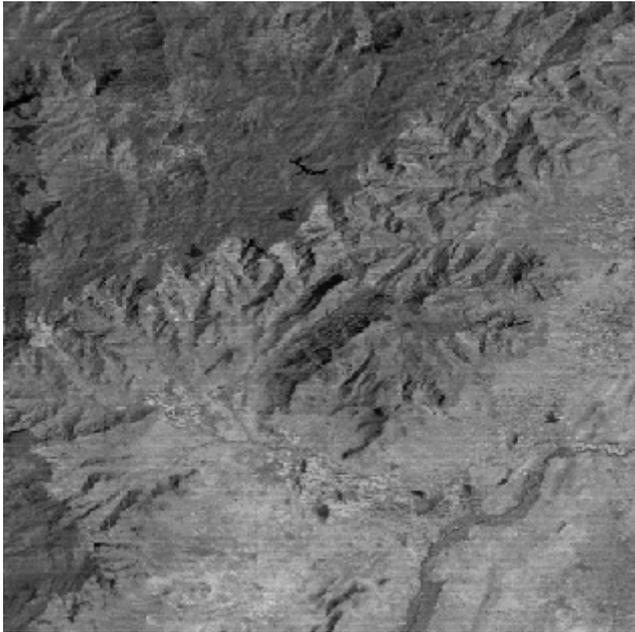
- Premier cliché initial (palni1)



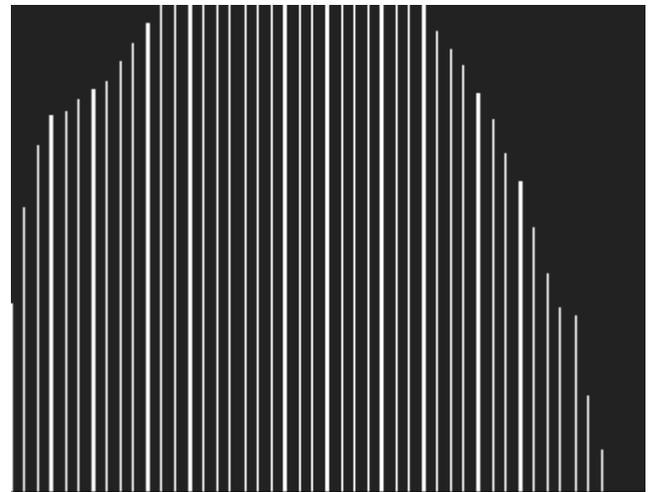
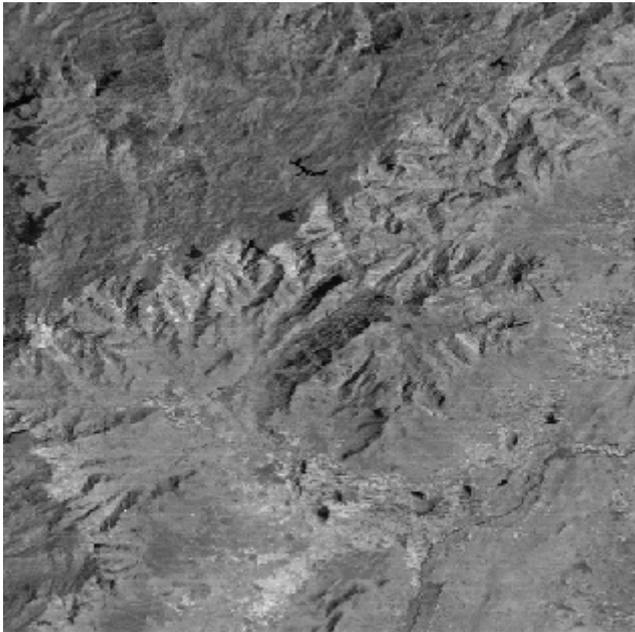
- Second cliché initial (palni2)



- Troisième cliché initial (palni3)



- Quatrième cliché initial (palni4)



4- L'algorithme

On va maintenant traiter de l'algorithme nécessaire à la programmation d'une telle analyse :

Voici les principales étapes :

1. Récupération des quatre clichés initiaux sous forme de vecteurs. Ces quatre vecteurs forment une seule matrice.
2. On centre cette matrice (grâce aux moyennes des quatre clichés)
3. On calcule la matrice de covariance associée.

4. On rend cette matrice diagonale.
5. On trie les valeurs propres et vecteurs propres associés obtenus.
6. On normalise les vecteurs propres pour obtenir une nouvelle base orthogonale.
7. On projette les pixels de nos clichés dans cette nouvelle base orthogonale.
8. On obtient de nouveaux clichés dont on fait l'hypothèse qu'ils suivent une distribution gaussienne.
9. On élimine les points très étalés sur cette gaussienne. C'est à dire qu'on ramène les pixels inférieurs à $-1,96 \sigma$ à cette valeur et les pixels supérieurs à $+1,96 \sigma$ à cette valeur.
10. On linéarise le contraste entre les valeurs 0 et 255.

a- Application

Voici la matrice de covariance (mat_cov) associée à la matrice des clichés :

1016.6186	1188.3243	843.44144	532.80289
1188.3243	1580.0267	948.3825	520.83269
843.44144	948.3825	1023.7265	824.84849
532.80289	520.83269	824.84849	832.61313

La variance du deuxième cliché est la plus élevée. Le deuxième cliché est donc le plus contrasté. La diagonalisation de la matrice de covariance donne les valeurs et vecteurs propres suivantes :

λ_i :

3642.657	60.888984	717.27412	32.164731
----------	-----------	-----------	-----------

u_i :

0.5069752	- 0.8183669	0.2331247	0.1374938
0.6095319	0.5586947	0.5369029	0.1675302
0.4956857	0.0660286	- 0.3902207	- 0.7730872
0.3546021	0.1173713	- 0.7107151	0.5961252

Il n'est pas nécessaire de normaliser les vecteurs u_i puisqu'ils le sont déjà, il n'y a qu'à les trier dans l'ordre décroissant :

λ_i :

3642.657	717.27412	60.888984	32.164731
----------	-----------	-----------	-----------

u_i :

0.5069752	0.2331247	- 0.8183669	0.1374938
0.6095319	0.5369029	0.5586947	0.1675302
0.4956857	- 0.3902207	0.0660286	- 0.7730872
0.3546021	- 0.7107151	0.1173713	0.5961252

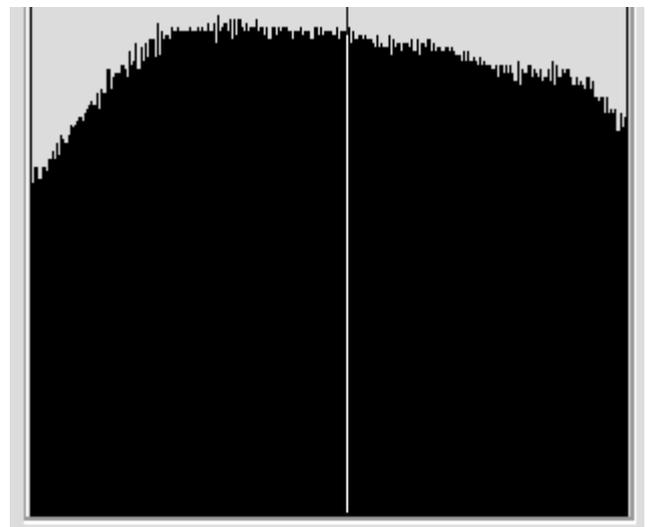
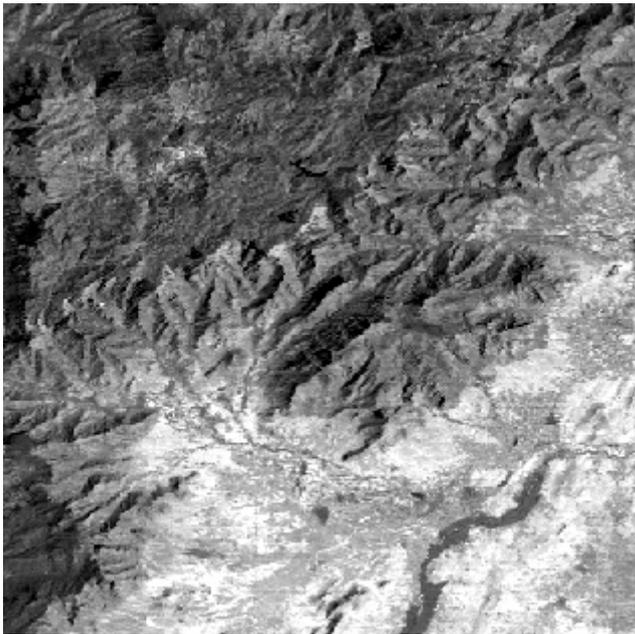
On peut alors obtenir la pertinence en % du premier cliché résultant en effectuant le rapport (valeur propre max / somme des valeurs propres)=82%

L'histogramme obtenu est Gaussien et la quasi totalité des pixels sont compris entre $-1,96 \sigma$ et $+1,96 \sigma$ (pour ceux qui sont hors de cet intervalle, on les fixe à $\pm 1,96\sigma$).

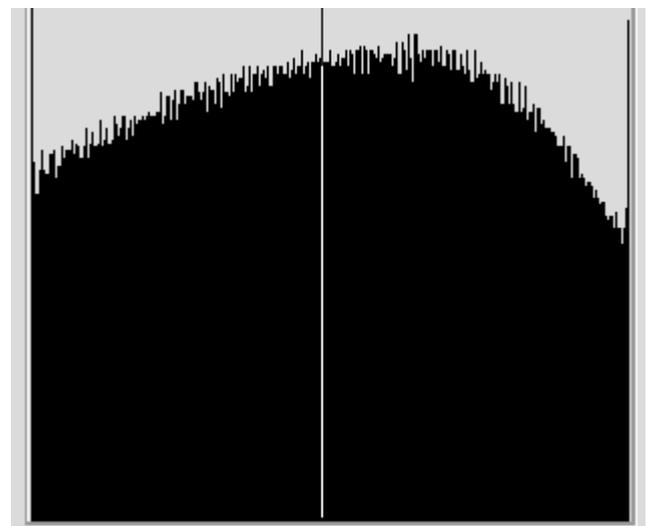
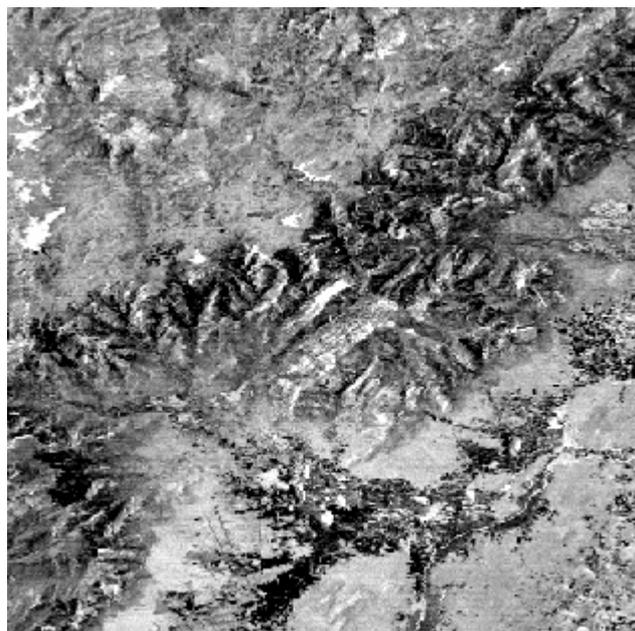
b- Résultats

Voici les quatre nouveaux clichés obtenus grâce à l'analyse en composantes principales :

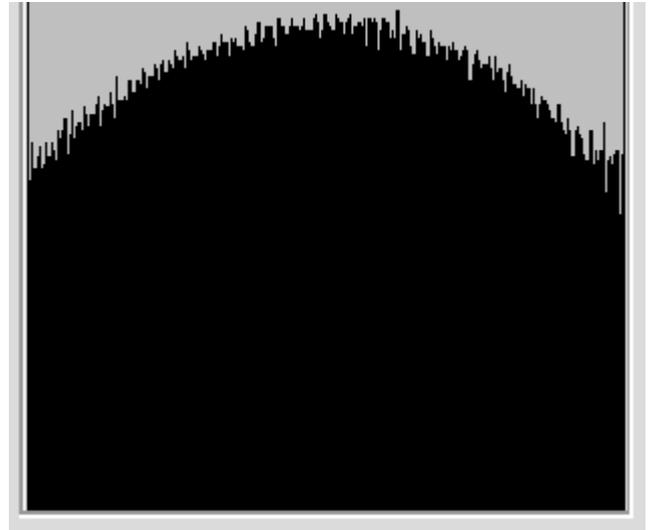
- Premier cliché obtenu (palni_etale1)



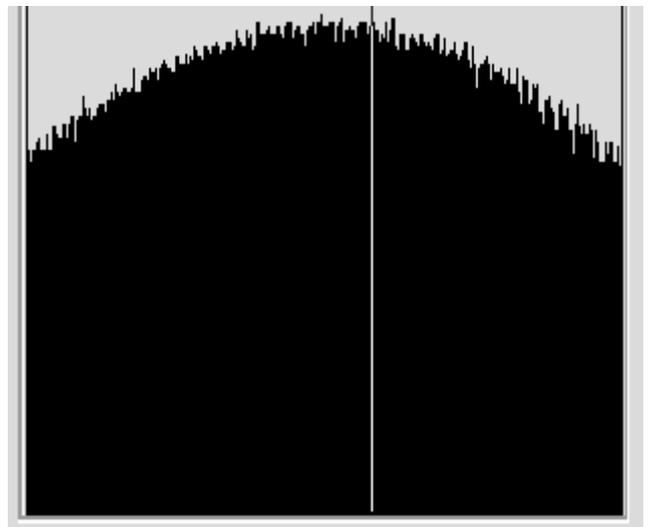
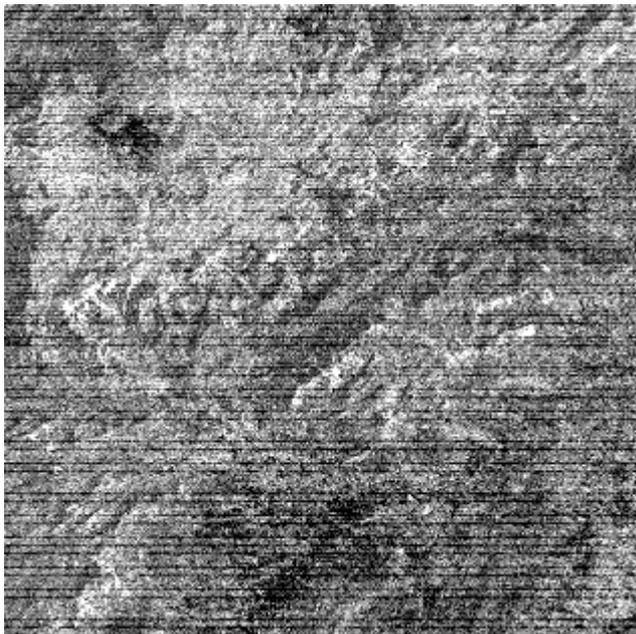
- Second cliché obtenu (palni_etale 2)



- Troisième cliché obtenu (palni_etalé 3)



- Quatrième cliché obtenu (palni_etalé 4)



On a travaillé ici avec des images multispectrales à quatre canaux. Pour pouvoir afficher l'image complète par synthèse trichromatique, il est nécessaire de ramener ce nombre de canaux à trois (comme le RVB par exemple). L'ACP permet cette réduction :

- Canal 1 : brillance globale de l'image.
- Canal 2 : différences spectrales entre les canaux sources de l'image.
- Canal 3 : bruit résiduel.

II- Classification Bayesienne

1- Introduction à la classification Bayesienne

La classification d'images fait partie des méthodes couramment utilisées pour exploiter des images satellitaires d'observation de la terre. Elle consiste à affecter à chaque entité de la scène traitée une étiquette indiquant son appartenance à une classe particulière. L'entité utilisée caractérise généralement le pixel ou une région de pixels tandis que l'étiquette constitue un thème choisi par l'utilisateur, par exemple la végétation, pour quantifier l'occupation des sols.

Les images satellitaires prises par télédétection sont classées par des méthodes dites de classification multispectrale, qui permettent d'affecter chaque pixel à une classe qui représente le thème du terrain. Les méthodes de classification sont fondées sur des concepts probabilistes et statistiques et sont donc soumises à des erreurs de précision et d'estimation. De nombreux algorithmes de classification existent et la majorité d'entre eux repose sur la théorie Bayesienne qui consiste à modéliser les classes selon des lois gaussiennes.

Historique :



Le révérend Thomas Bayes (1702-1760), pasteur et mathématicien anglais, a exposé sa théorie des probabilités dans un essai publié à Londres en 1764, après sa mort, par la Royal Society dont il était membre depuis 1742.

Dans la Théorie analytique des probabilités, Pierre-Simon de Laplace (1749-1827) développe les principes et les méthodes qu'il applique, au fil des éditions successives de 1812 à 1825, à toute une série de problèmes de statistiques, de probabilités et de calculs d'erreurs.

La théorie des probabilités se développe très vite à cette époque, avec les travaux de Joseph Fourier (1768-1830), de Denis Poisson (1781-1840) dont la distribution apparaît en 1837 dans sa Recherches sur la probabilité des jugements, et bien sûr de Karl-Friedrich Gauss (1777-1855).

Adolphe Quételet (1796-1874) pousse à l'utilisation des statistiques dans le domaine social, et il est un des premiers à considérer la distribution normale (ou distribution de Gauss) ailleurs que dans le calcul d'erreurs (Sur l'homme et le développement de ses facultés, essai de physique sociale, 1835).

L'approche "naturelle" des probabilités suivie par Bayes, Laplace et leurs successeurs a été largement remplacée au XX^{ième} siècle avec l'approche "axiomatique":

Karl Person (1857-1936) : inventeur du terme "écart standard".

Sir Ronald Fisher (1890-1962) : inventeur du maximum de vraisemblance

Jerzy Neyman (1894-1981) et Egon Pearson (1895-1980, le fils de Karl Pearson) : auteurs du test d'hypothèse de Neyman-Pearson.

Andrei Kolmogorov (1903-1987) qui a donné en 1933 une base axiomatique à la théorie des probabilités (ainsi que d'importantes contributions à différentes branches des mathématiques).

2- Théorie

On suppose que la loi de probabilités qui régit l'observation est une loi normale.

Loi normale.

$$N(m, \sigma) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x-m}{\sigma} \right)^2}$$

Probabilité a posteriori pour une loi normale .

$$P(W_k / X) = \frac{P(X / W_k) \cdot P(W_k)}{\sum_{k=1}^m P(X / W_k) \cdot P(W_k)}$$

a- La décision Bayesienne.

Considérons $\Omega = \{w_1, \dots, w_m\}$ l'ensemble des états possibles.

$A = \{\alpha_1, \dots, \alpha_n\}$ l'ensemble des décisions possibles.

Et $X = \{x_1, \dots, x_n\}$ l'ensemble des données.

D'après la règle de Bayes la probabilité que x appartienne à l'état w_j est tel que :

$$P(w_j | x) = p(x | w_j) \cdot P(w_j) / p(x)$$

Avec $p(x | w_j)$ la densité de probabilité de x sachant son appartenance à w_j ,

$P(w_j)$ la probabilité a priori de la classe w_j .

Et $p(x)$ la fonction de densité de probabilité de l'ensemble des fonctions de densité des 'i' classes.

On choisit ensuite la décision optimale en calculant le coût moyen d'appartenance de x à chaque classe c'est à dire $R(\alpha_i | x)$ et on affecte à x la classe pour laquelle le coût moyen est minimal.

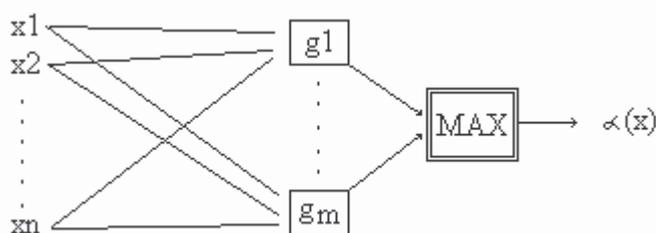
Ainsi on choisit α_i tel que $R(\alpha_i | x)$ minimum en calculant pour tout $i = 1, \dots, n$.

$$R(\alpha_i | x) = \sum_{j=1}^m r(\alpha_i / w_j) P(w_j | x)$$

Nous utilisons une fonction discriminante pour la loi normale.

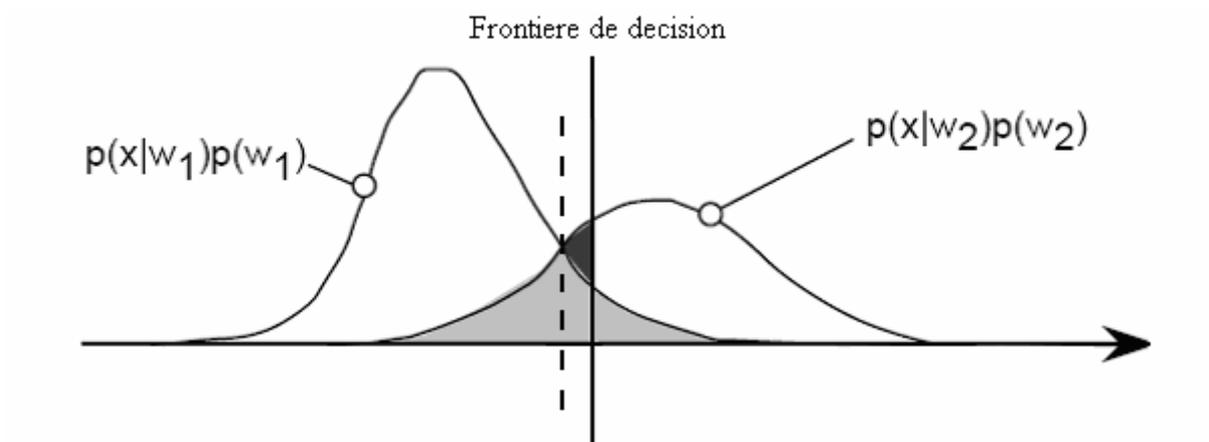
Nous avons donc utilisé une fonction de classement par taux d'erreur minimal, représenté par la formule ci dessus.

b- La fonction discriminante :



Le calcul des fonctions discriminantes pour chaque observation x permet de sélectionner la classe avec le discriminant maximum. C'est à dire que si $g_i(x) > g_j(x)$ quel que soit j compris entre 1 et m , alors on assigne x à la classe w_i .

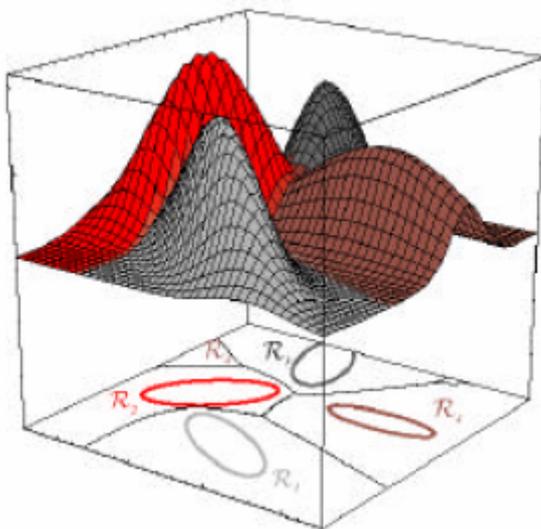
Si l'évaluation de x par deux fonctions discriminantes est égale et maximum, c'est la frontière de décision. On ne peut décider !



Par exemple en gris clair sur le schéma on ne peut prendre la décision car il y a possibilité d'erreur ! En gris foncé la décision est erronée car le seuil est mal placé.

La frontière idéale serait la ligne en pointillé tracé à côté.

Exemple de fonction discriminante avec 3 paramètres de mesure.



Le choix des fonctions discriminantes n'est pas unique.

Dans la fonction discriminante, l'ensemble des prototypes représentatif de chaque classe est utilisé pour estimer les paramètres des fonctions de densité.

3- Algorithme

Notre algorithme se décompose en plusieurs étapes.

1er étape : Chargement des données nécessaires à l'étude.

- Les 4 images Palni.
- Et les échantillons de l'expert.

Toutes ces données sont placées dans des matrices pour faciliter leurs utilisations.

2ème étape : Création des imagettes.

Création pour chaque image Palni d'une imagette représentant l'échantillon.

Etant donné que nous disposons de 3 échantillons par images Palni, nous avons fusionné les deux premières imagettes dans une matrice et gardé la troisième pour la validation.

3ème étape : Calcul des constantes.

Calcul des données nécessaires à la classification.

Calcul des moyennes.

Calcul des covariances.

La matrice de covariance nous renseigne sur la forme du groupement des observations autour du vecteur moyenne calculé précédemment.

Pour ce calcul des covariances on peut utiliser une fonction biaisée ou non biaisée. Les résultats restent les mêmes.

Calcul des constantes utiles au calcul de la fonction discriminante.

Ceci pour diminuer le temps de calcul du programme

$$P(C_k | X) = \max \left\{ \frac{1}{|\Phi_k|} \exp \left\{ -\frac{1}{2} (\underline{X} - m_k)^T \Phi_k^{-1} (\underline{X} - m_k) \right\} \right\}$$

Voici ci dessus soulignés les éléments pré calculés de la fonction discriminante...

4ème étape : Classification

Pour chaque points de l'image, (Un point de l'image est vecteur composé des quatre points positionne à la même places sur les quatre images Palni) on calcul des probabilités d'appartenances à chaque classe en utilisant le calcul de la fonction discriminante.

On affecte chaque pixel la classe ou il a la probabilité d'appartenance la plus grande.

Création de l'image résultat.

5ème étape : Validation.

Construction de la matrice de confusion.

Chaque élément $conf[i][j]$ de cette matrice représente le pourcentage de points de l'échantillons de validation représentant la classe i et classés dans la classe j.

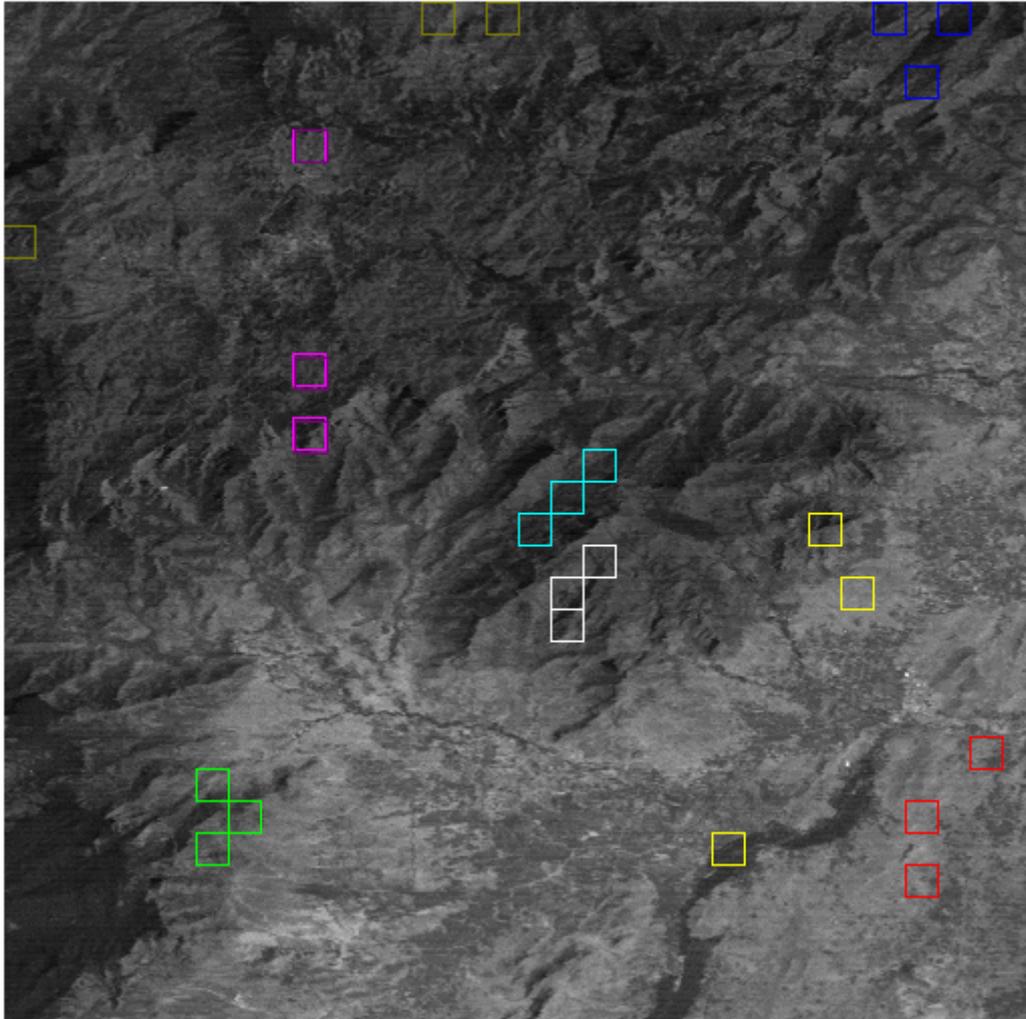
4- Analyse du cas des images Palni

Voir présentation des images Palni dans l'introduction.

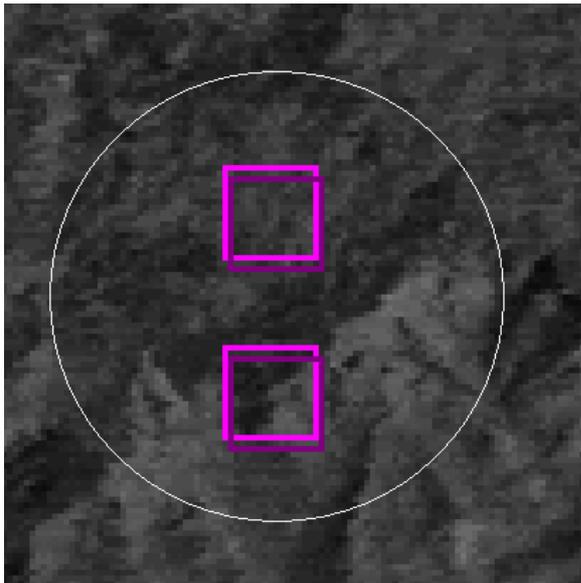
Notre objectif dans ce TP était de réaliser à partir de quatre images satellite d'une même région terrestre, une cartographie localisant spatialement dans l'image les différents éléments de la scène : forêts, eau, végétation ...

Cette classification Bayésienne est effectuée en mode supervisé. C'est à dire que nous disposons des échantillons d'un expert. Ces échantillons sont localisés dans l'image et représentent les différents éléments de la scène. Ils correspondent aux couleurs suivantes :

- Echantillon 1 : Imagettes marron.
- Echantillon 2 : Imagettes bleues.
- Echantillon 3 : Imagettes vertes.
- Echantillon 4 : Imagettes cyans.
- Echantillon 5 : Imagettes blanches.
- Echantillon 6 : Imagettes magenta.
- Echantillon 7 : Imagettes jaunes.
- Echantillon 8 : Imagettes rouges.
- Echantillon 9 : Imagettes violettes.



Il y a 9 échantillons composés 3 imagettes différentes chacun.
Mais il faut préciser que deux échantillons (échantillons 6 et 9) sont presque identiques. On peut les distinguer a sur l'image ci dessous ...



Les deux classes Magenta et Violette sont presque confondues ...

a- Observation des imagerie fournies par l'expert.

En regardant les imagerie fournies on peut déjà s apercevoir que la classe 7 (jaune) n'est pas sélective d'un type de terrain, car les 3 imagerie de cette classe représente des zones de terrains différents (montagne, rivière et plaine). On peut dire que les résultats pour ces échantillons ne seront pas brillants.

Les imagerie rouges représentent par contre un terrain semblable (plaine) donc les résultats devraient être meilleurs.

Comme préciser précédemment les imagerie des classes 6 et 9 sont confondues les résultats pour ces classes seront donc presque les mêmes.

b- Analyse des résultats après classification par la méthode de BAYES.

On obtient les résultats suivants :

MATRICE DE CONFUSION

1	2	3	4	5	6	7	8	9
11.764706	29.411765	0.	29.411765	0.	23.529412	0.	0.	5.8823529
23.529412	41.176471	5.8823529	17.647059	11.764706	0.	0.	0.	0.
5.8823529	0.	47.058824	0.	41.176471	0.	5.8823529	0.	0.
29.411765	5.8823529	11.764706	35.294118	5.8823529	0.	5.8823529	0.	5.8823529
5.8823529	0.	52.941176	0.	17.647059	5.8823529	11.764706	0.	5.8823529
0.	29.411765	0.	11.764706	5.8823529	35.294118	0.	0.	17.647059
0.	0.	64.705882	0.	23.529412	0.	11.764706	0.	0.
0.	0.	0.	0.	0.	0.	0.	100.	0.
0.	76.470588	0.	17.647059	0.	5.8823529	0.	0.	0.

TAUX GLOBAL = 33.333333 %

Dans le meilleur des cas avec des échantillons parfaits de l'expert on devrait obtenir environ 100 % cent sur toute la diagonale de la matrice de confusion.

Dans notre cas seul les classes 2, 3, 4, 6 et 8 ont leur valeur maximum sur bien placés sur la diagonale.

Classe 1 : Imagettes marron.

Cette classe est corrélé avec les classes 2, 4, 6 ainsi l'information donnés par cette classe n'est pas pertinentes. Dans la version améliorée cette classe a été supprimée.

Classe 2 : Imagettes bleues.

Sa valeur maximum est 41 % (ce qui est un taux plutôt bon) et elle est bien placée sur la diagonale de la matrice de confusion, en effet à l'observation des échantillons on peut voir que les trois imagettes se représente la même zone de terrain sur l'image. Cette imagette reste néanmoins corrélée avec la 1 et 4.

Classe 3 : Imagettes vertes.

Sa valeur maximum est 47 % et elle est bien placée sur la diagonale.

Elle est cependant très corrélée avec la 5. Ce qui explique pourquoi la 5 n'est pas sur la diagonale de la matrice de confusion.

Classe 4 : Imagettes cyans.

Sa valeur maximum est 35 % et elle est bien placée sur la diagonale.

Elle est cependant très corrélée avec la 1.

Classe 5 : Imagettes blanches.

Cette classe ci a sa valeur maximum mal placée sur la matrice et elle est très corrélé avec la 3 on retrouve d'ailleurs sont maximum en colonne 3.

Classe 6 : Imagettes magenta.

Sa valeur maximum est 35 % et elle est bien placée sur la diagonale.

Elle est cependant corrélée avec la 2.

Classe 7 : Imagettes jaunes.

Comme on pouvait s'y attendre du fait que les trois imagettes représente des zones de terrains différente valeur maximum de cette classe n'est pas sur la diagonale. Elle est corrélé avec les classe 3, 5 et 7 et son taux en colonne 3 est très important 64 %. Cette imagette est donc plus représentative de la classe 3. C'est pour cela que cette classe a été supprimée dans la version amélioré de la classification.

Classe 8 : Imagettes rouges.

Rien à dire pour cette classe le résultat est parfait 100%.

Classe 9 : Imagettes violettes.

Sa valeur maximum est 76 % sur la colonne 2.

Cependant sur la diagonale la valeur est 0.

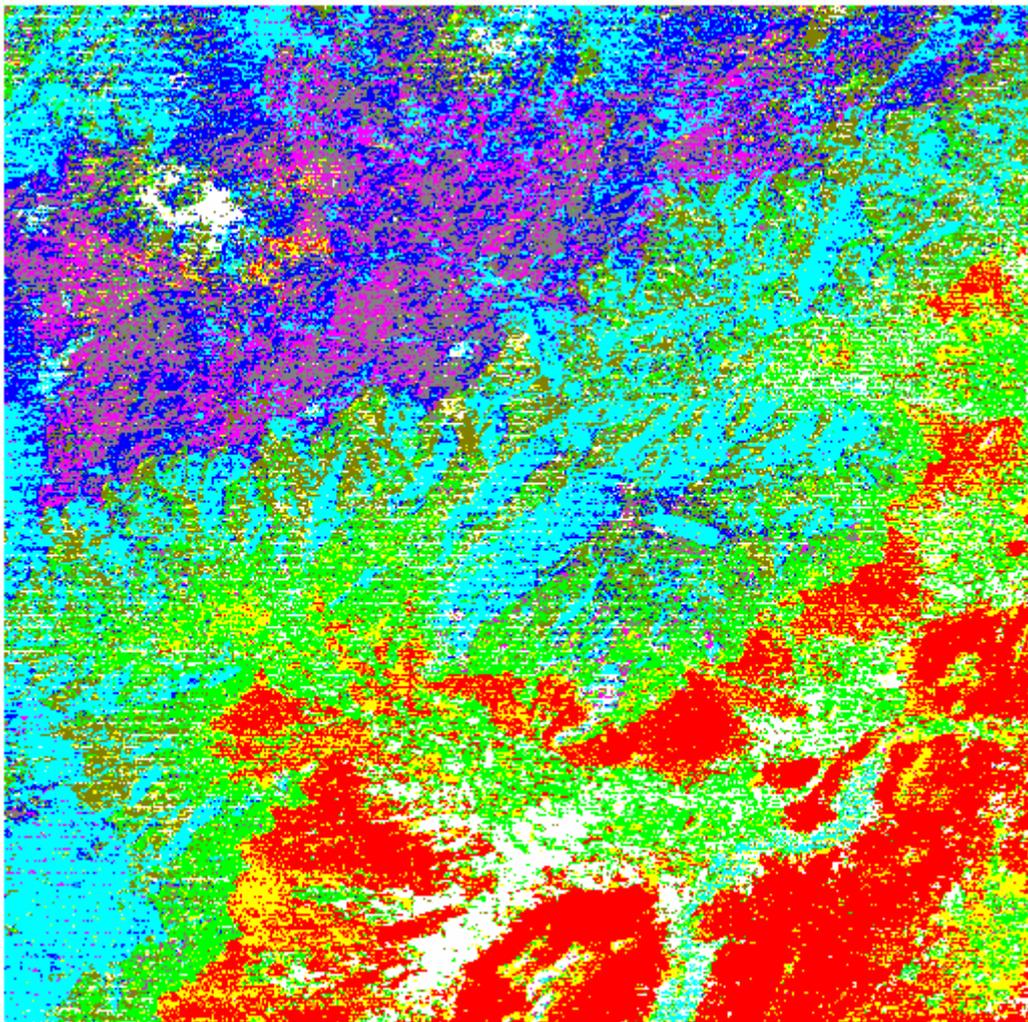
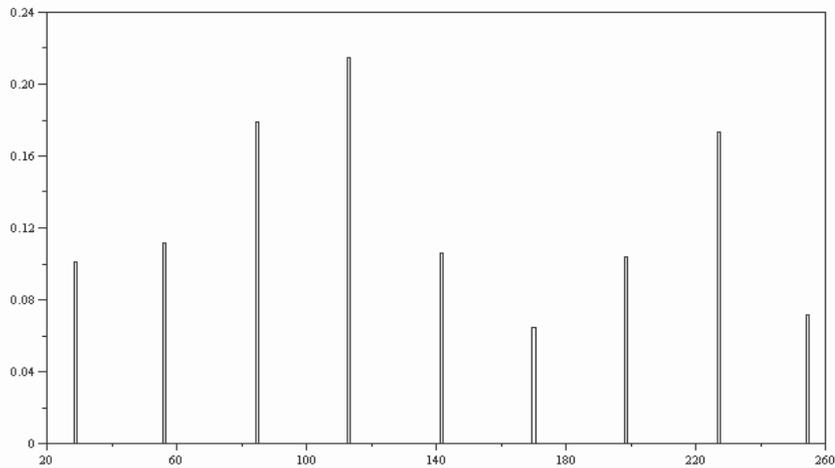
Cet échantillons est très représentatif de la classe 2.

En plus comme on l'a précisé précédemment elle contient les mêmes informations que la classe 6.

c- Ce que l'on retient de l'étude.

Dans la plaine le résultat de classification est plutôt bon.

En ce qui concerne la partie montagne l'image est plutôt embrouillée car il y a plusieurs mélanges de couleurs dus probablement aux échantillons qui représentent des zones non homogènes. Ci-dessus l'histogramme et l'image après classification.



d- Version améliorée de classification.

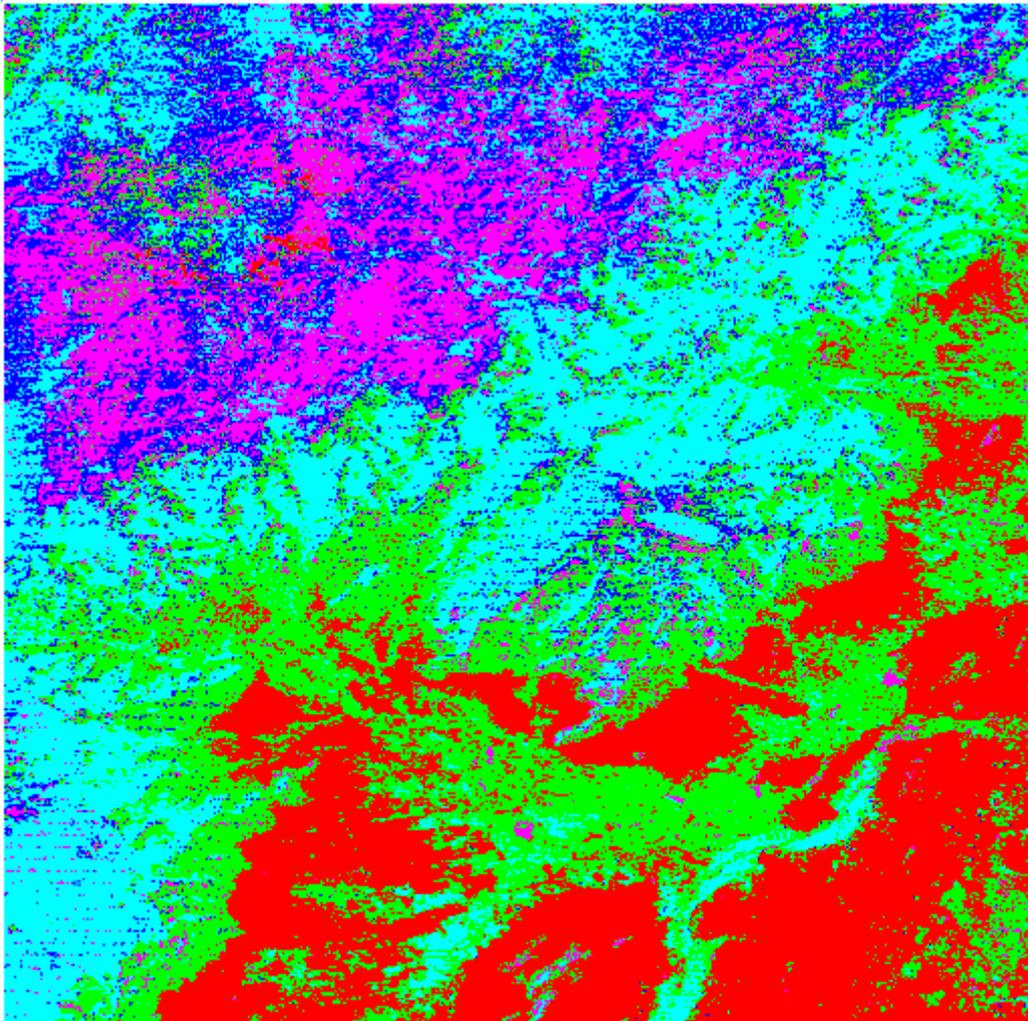
Nous avons supprimé les classes trop corrélées ou contenant les mêmes informations qu'une autre.

MATRICE DE CONFUSION

2)	41.176471	94.117647	52.941176	52.941176	100.
3)	41.176471	29.411765	29.411765	0.	0.
4)	0.	94.117647	5.8823529	0.	0.
5)	11.764706	29.411765	52.941176	5.8823529	0.
6)	35.294118	0.	11.764706	52.941176	0.
8)	0.	0.	0.	0.	100.

TAUX GLOBAL = 68.235294 %

Toutes les autres classes trop corrélées ont été supprimées. C'est à dire les classes 1, 7 et 9.



Puisque l'on a réduit le nombre de classes les mélanges sont moins marqués et on obtient donc une meilleure classification. Avec ce résultat on peut différencier plus facilement les différentes zones terrains de l'image (plaine, montagne, haute montagne, rivière ...).

5- Conclusion sur la Classification Bayésienne

La classification Bayésienne ne permet pas avec nos échantillons l'obtention de très bons résultats. Car le taux globale classification est de 33,33 % .Donc, Les échantillons de l'expert sont parfaits. Malgré cela en retravaillant le résultat et en supprimant quelque classe vu a nos yeux d'inutiles on se ramène a un taux de 68 % ce qui devient un taux raisonnable.

L'algorithme qui repose sur la théorie Bayésienne consiste à modéliser les classes selon des lois gaussiennes. Cependant, les images satellitaires à classier n'obéissent généralement pas à ces lois. Pour palier à ce problème, nous pouvons exploiter les réseaux de neurones qui n'ont pas besoin d'une connaissance préalable des lois associés aux classes. Ainsi pour les mêmes échantillons une classification par KOHONEN nous a donné un taux global sur le m'image classifiée de 40%.

Conclusion

L'étude de ces deux méthodes de traitement d'images numérique nous a apporté les réponses suivantes. Ces deux méthodes étudiées sont complémentaires.

L'ACP est méthode préliminaire à une méthode classification car elle permet de déterminer les paramètres qui seront les plus pertinents pour une éventuelle classification.

La méthode de classification est quant à elle une méthode permettant de déterminer les différentes classes d'une image. Mais comme elle s'effectue en mode supervisé elle nécessite les données préalables d'un expert. Cette méthode peut toutefois être remplacée par une classification par un réseau de neurones tel qu'une carte de Kohonen.