



Caractérisation de l'occupation du sol par télédéttection

« Techniques d'observation et méthodes d'analyse pour la gestion
de l'eau dans les bassins versants agricoles méditerranéens »

École d'hiver du 2 au 6 mars 2015,
INAT (& Univ. Carthage, IRESA), Tunis, Tunisie


Vincent Simonneaux – CESBIO, Toulouse




Interprétation des images satellitaires

=> Transformer l'information physique, la **signature spectrale**, des images
information thématique (occupation du sol, végétation, sols, etc.)

Image satellitaire
brute






**Classification de
l'occupation du sol**



Classes A, B, C... = Carte Choroplèthe
Variable qualitative (classes A,B,C...)

Variable quantitative
(LAI, %H2O, etc.)




Echelle et classification

La surface du sol peut être modélisée par une hiérarchie d'objets emboîtés

L'observateur se focalise (parfois implicitement) sur un niveau d'observation selon la zone étudiée, la thématique abordée, les entités fonctionnelles d'un modèle...

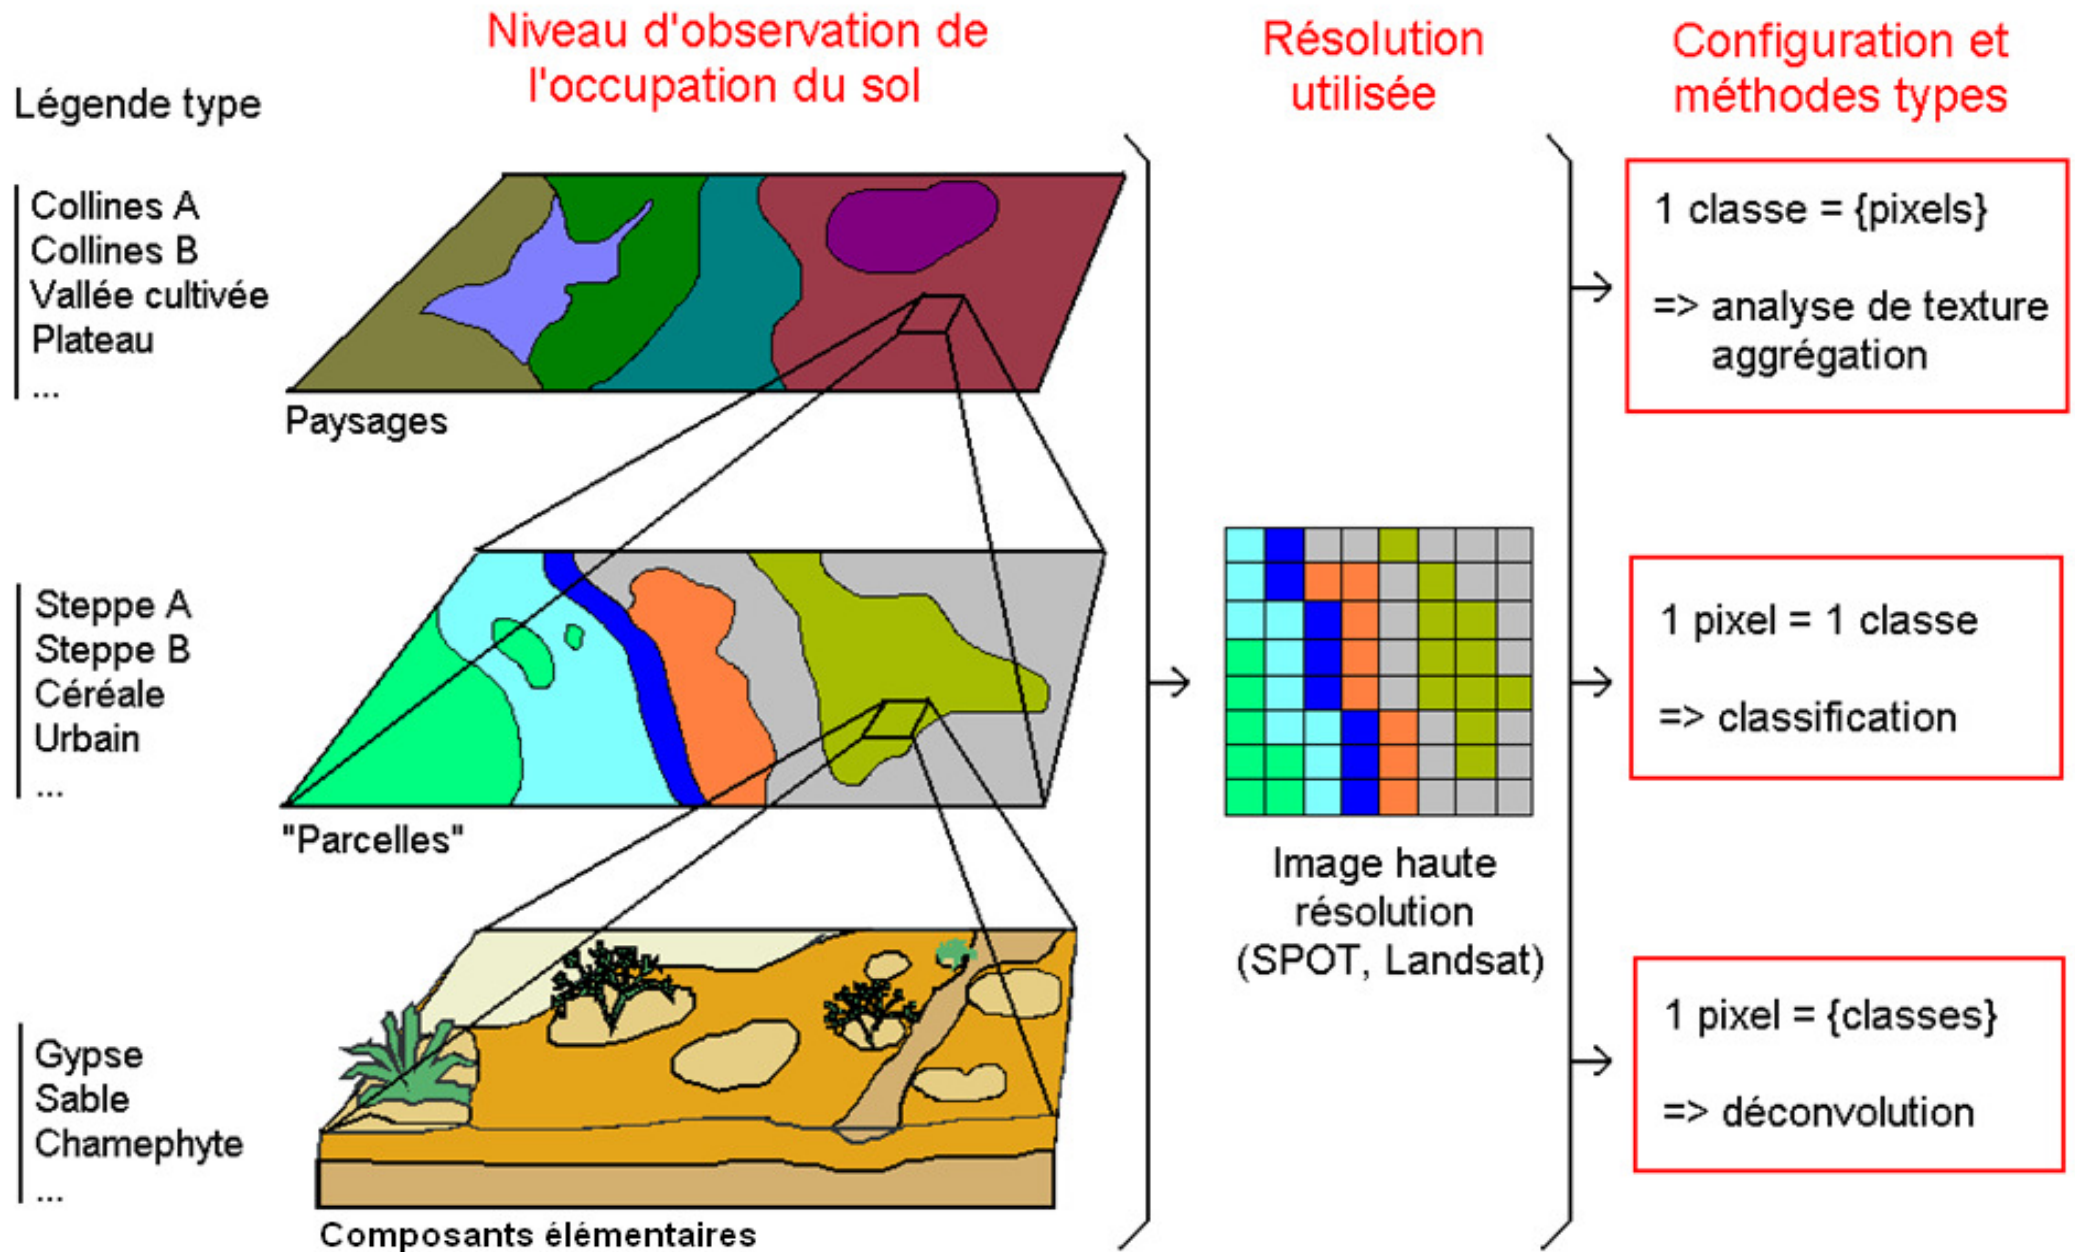
=> « Modèle » de l'OS

Echelle d'observation
de la surface



Echelle et classification

Domination des méthodes statistiques type « *Maximum de vraisemblance* »
Mais il existe des alternatives, notamment selon l'échelle d'intérêt

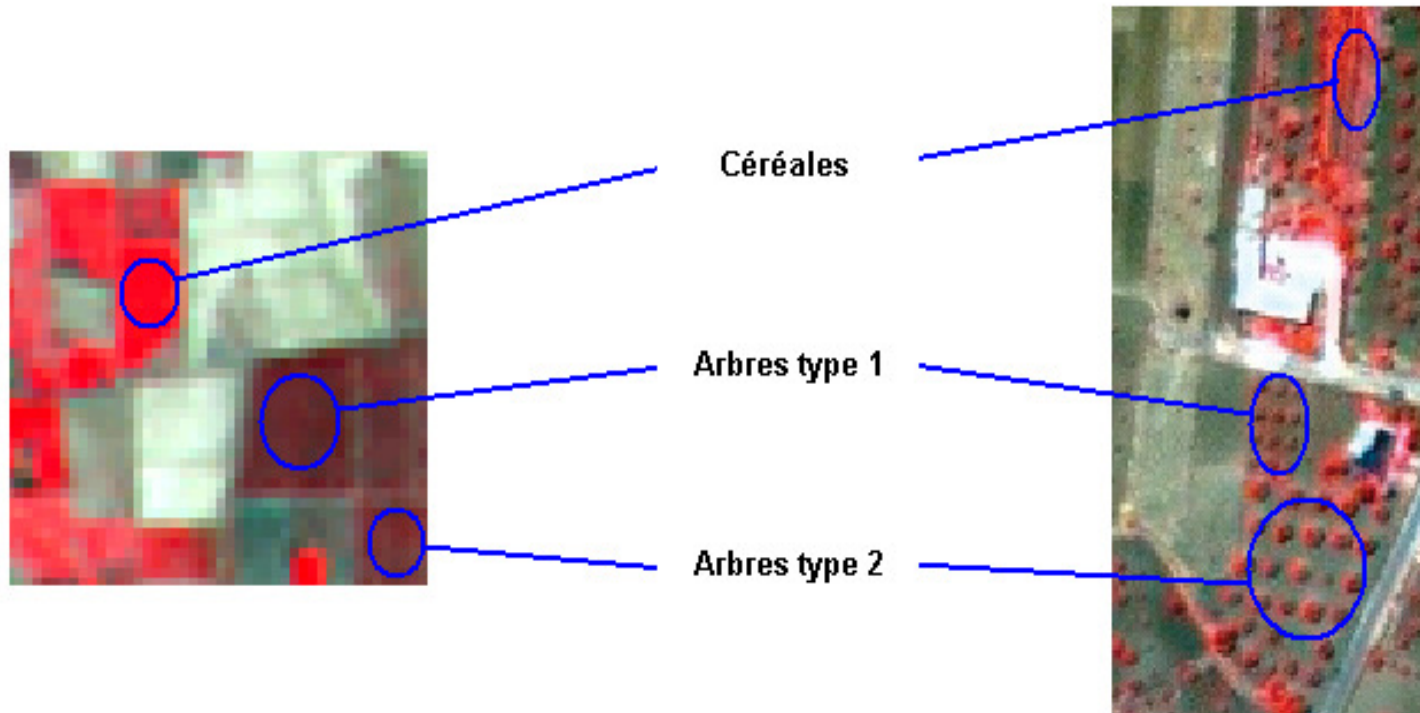


Echelle et classification

Résolution et structure

"Basse résolution"

"Haute résolution"



Echelle / objet d'étude et résolution doivent être compatibles

Résolution et outils doivent être compatibles

Echelle et classification

Exemples

- 1 pixel = { classes }

ex : Image HR (ex SPOT HRV, Landsat...) et formation steppique
Image MR-BR (MODIS, PROBA-V, S3...) et parcelle agricole

- 1 pixel = 1 classe

ex : Image HR et parcelle agricole
Image MR-BR et paysage

- 1 classe = { pixels }

ex : Image HR et paysage
Image THRS (~1 m) et formation arborée




1 pixel = 1 classe

Principe de la classification

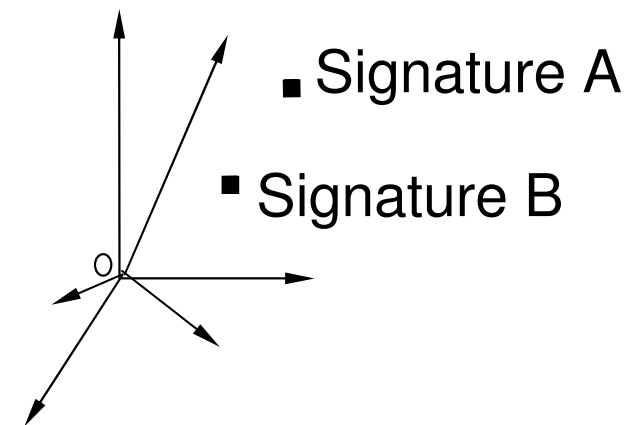
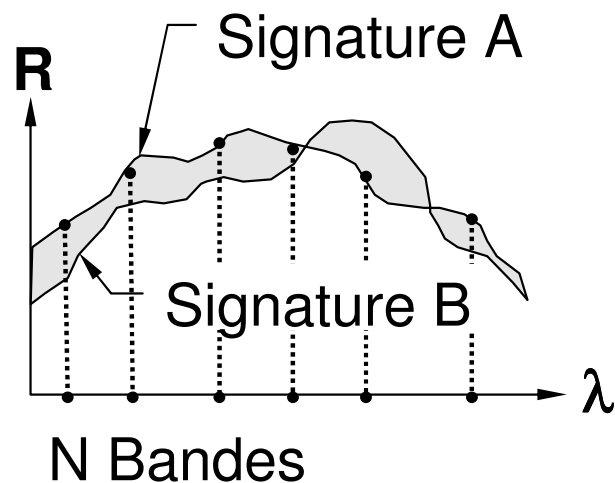
Données satellitaires

On quitte l'espace géographique pour ce placer dans **l'espace des signatures**



Pixels A et B
d'une image
à N canaux

Equivalence




**Espace à N
dimensions**

Principe de la classification

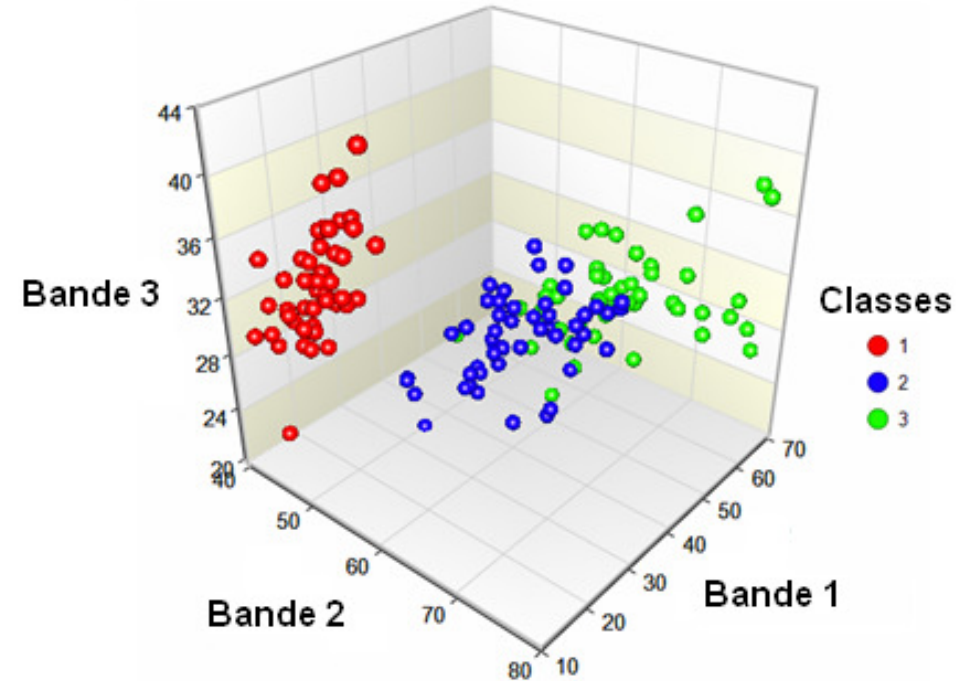
⇒ Partition du nuages des signatures

Objectif : 1 signature => 1 classe

Ex d'espace à 2 dimensions




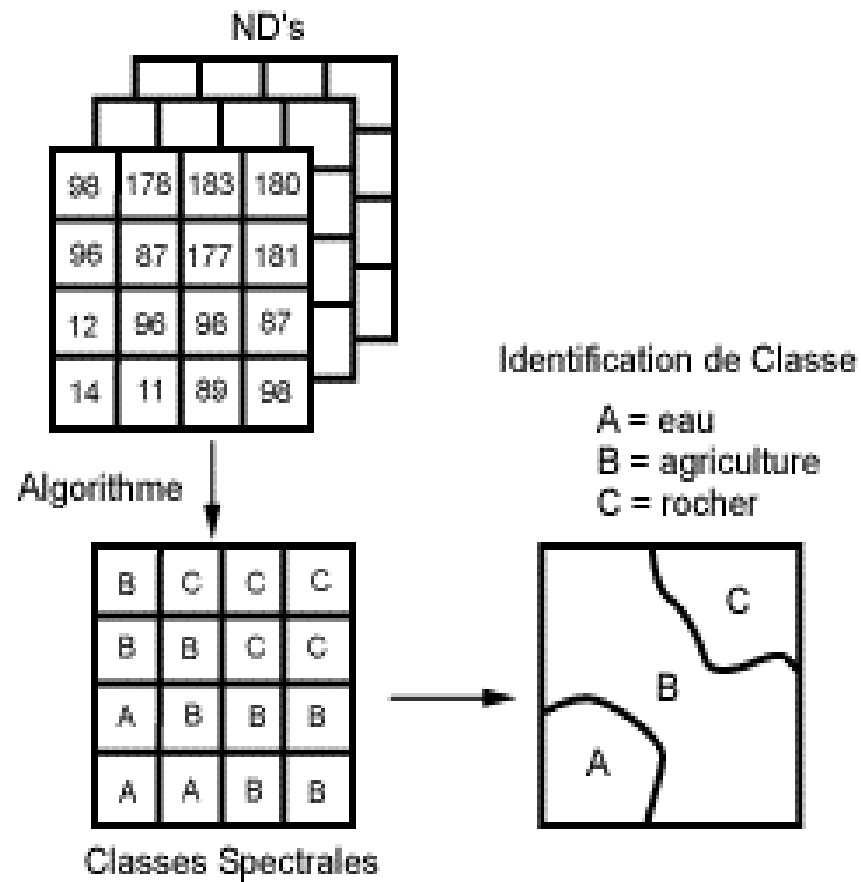
Ex d'espace à 3 dimensions



Principe de la classification

Classification non supervisée

Classification supervisée



Supervisée ou non supervisée ?

Si typologie existante et classes distinctes et homogènes

=> **classification supervisée** utilisable (non supervisée aussi ...)

- **Si typologie complexe**

- Mal définie a priori (pas de vision claire de l'utilisateur)

- Classes hétérogènes (nuages irréguliers), il est difficile de choisir des parcelles d'apprentissage qui donneront une partition correcte. Ex en milieu naturel la notion de classe délimitée est virtuelle, souvent continuum

=> « *Laisser parler les données* » => **Classification non supervisée.**

Stratégie classique : demander de nombreuses classes, les identifier puis les regrouper.

« *Il vaut mieux des classes mixtes que des fausses classes pures* »

- **Interprétation visuelle** de l'image ...

Prise en compte du **contexte** : hétérogénéité spectrale, analyse du paysage (implicite et puissant)

- **Classification statistique classique**

Modèle « **centroïde - distance** » sur les bandes ou combinaisons (ex « maximum de vraisemblance »)

- **Classification avec frontières plus complexes « moins paramétriques »** (ex. réseau de neurones (NN), SVM...)

Plus proche des frontières réelles que centroïde-distance

- **Classification par « arbre de décision »**


Simple seuils sur bandes ou indices (Si NDVI > 0.4 alors ...)

Souvent une signification thématique => expertise


- **+ Combinaisons de ces méthodes** (ex « random forest »)

Exemple du maximum de vraisemblance

Calcul de probabilité gaussienne à partir de l'échantillon d'apprentissage
=> Frontières simples (simplistes ?)



Exemple de frontières plus complexes (critère distance pondérée aux voisins)




Confusions

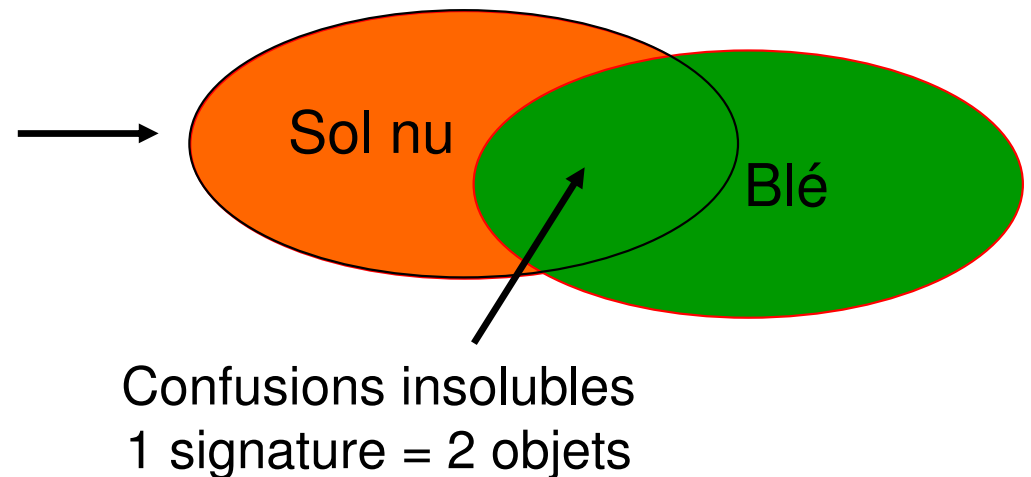
= mauvais classement de pixels

Attention...

- Confusions liées à l'**algorithme** donc potentiellement solubles par un algorithme performant



- Liées à la **signature spectrale** confusions « vraies », insolubles sans information supplémentaire



Confusions

Resolution des confusions dues à l'algorithme

- ⇒ Utiliser autre algorithme
- ⇒ Axes plus discriminants (indices, ACP...)
- ⇒ Découper en sous-classes (« clustering »)
- ⇒ **Reclass mixed classes** (using masks)

Confusions

Gestion des classes complexes

Découpage en sous classes

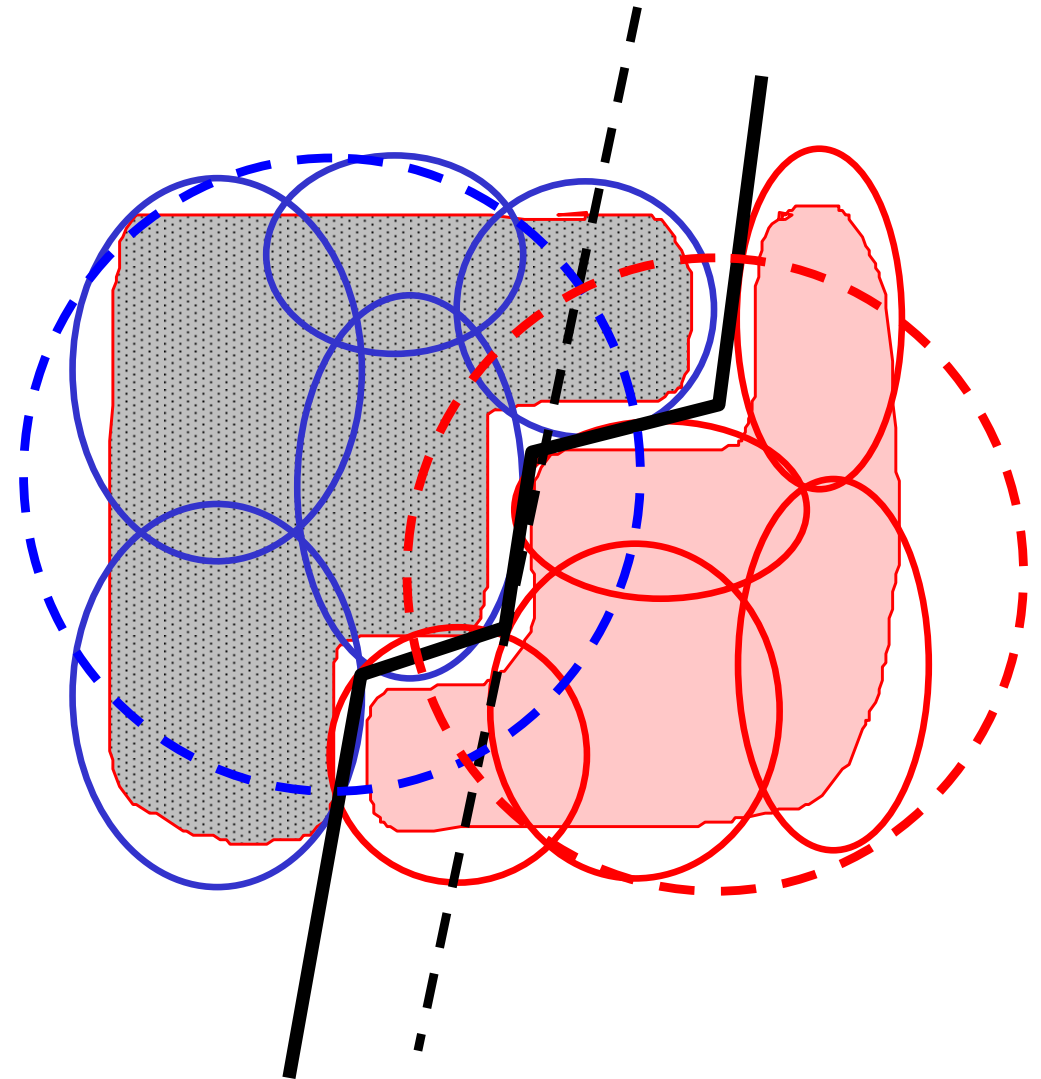


Frontière avec 2
classes initiales



Frontière avec 10
sous classes

=> **Moins de confusion**



Confusions

Résolutions des confusions « vraies »

⇒ Les algorithmes ne peuvent rien ! Il faut + d'information

- Choisir une typologie réaliste.
- Autres bandes / capteurs ou transformations
- Dates supplémentaires. Prise en compte de **l'évolution temporelle du pixel**
 - Classification statistique avec les dates considérées comme des bandes supplémentaires (prise en compte indirecte du temps)
 - Classification par critères de décision inspirés des processus écologiques : analyse explicite du cycle végétatif (« début », « fin », etc.)
- Informations **thématiques supplémentaires** (géologie, altitude, OS précédentes, etc.) => probabilités d'appartenance aux classes
- Stratification paysage
- Probabilités de **proximité spatiale** entre classes (Chorologie).
- Envisager des classes mixtes...

Méthodes de classification

Résolution des confusions

Choix des dates des images

Mois	Sept.	Oct.	Nov.	Déc.	Jan.	Fév.	Mars	Avril	Mai	Juin	Juillet	Août	Sept.	Oct.	
Betterave	Sol nu						S	↗ couvert						R	
Maïs	Sol nu							S	↗ couvert				R	R	
Blé d'hiver	Sol nu	S	↗ couvert						M	R	Sol nu				
Blé de printemps	Sol nu					S	↗ couvert				M	R	Sol nu		
Orge d'hiver	S	↗ couvert								M	R	Sol nu			

S : semis ou plantation **M** : maturation **R** : récolte

Une image de mars permet de distinguer les céréales de printemps et d'hiver.


Une image d'août montre les betteraves et le maïs.

Le Maïs et la betterave ne seront distingués que si les différences de structure de la végétation sont suffisantes pour influencer la signature spectrale

Méthodes de classification

Résolution des confusions

Exemple de stratification

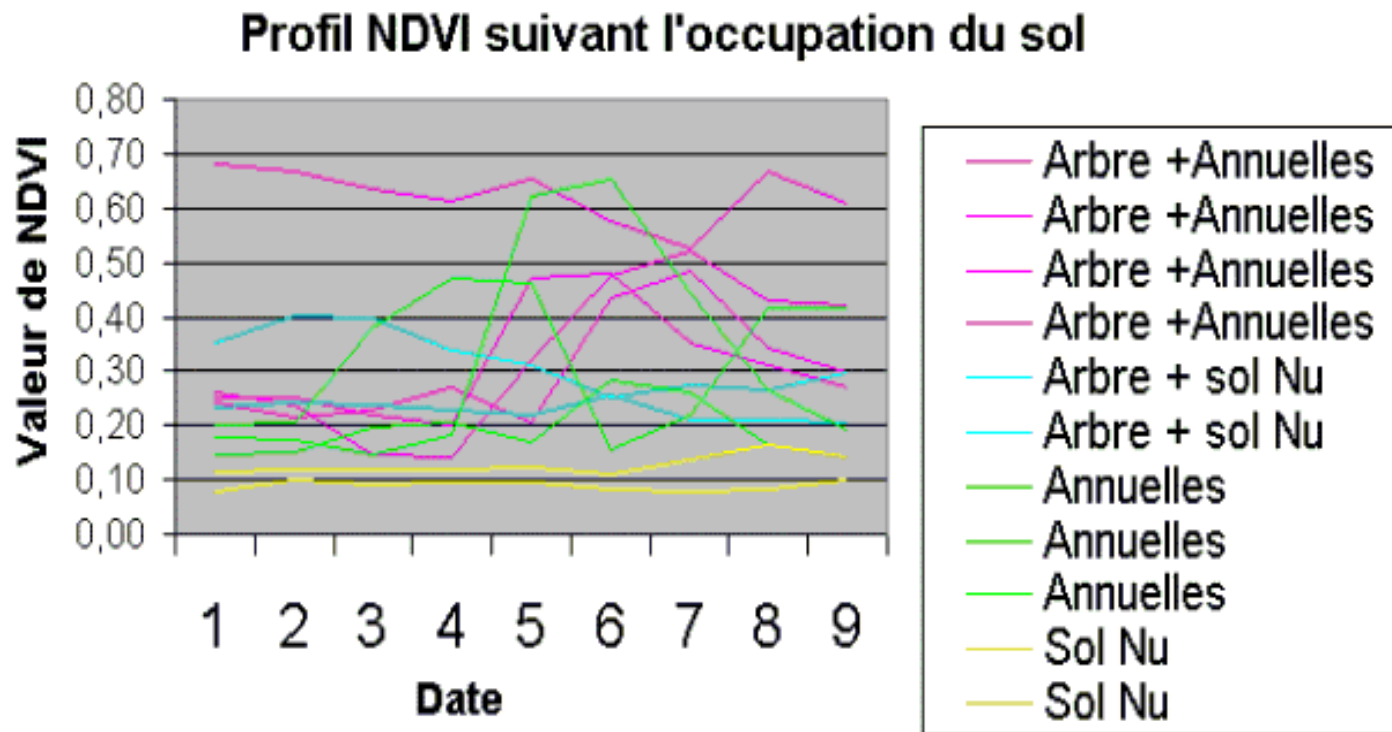


Utilisation de données exogènes (« ancillary data »)

- Soit utilisées de manière « déterministe »
 - Si vous connaissez les relations avec les classes d'OS
 - ex. - *juniper thurifera* seulement si altitude > 1800m
 - respect des rotations culturalesImplémentation à la main (masquage) ou avec fonctionnalités spécifiques (ex. ENVI decision tree)
- Soit ajoutées aux autres bandes, même algorithme
 - Si on ne connaît pas exactement les relations entre la variable et les classes
 - => pas très efficace, selon les algorithmes utilisés : risque d'apporter de la confusion dans les autres classes.


Analyse diachronique

Analyse déterministe de séries intra-annuelles



Cultures non synchrones

=> classes hétérogènes, les classifications à base de centroides ne fonctionnent pas



Analyse diachronique


- Analyse déterministe de séries temporelles

Critères agro-écolo : début, fin, min, max, pente, durée, etc.

Exemple sans prise en compte du temps (Haouz, Maroc, 2001)


1 - Identification d'un palier inférieur

→ Détection de végétation permanente



2 - Différence (maximum - palier)


→ Détection des cultures annuelles




Echantillonnage terrain

- **Taille minimale des parcelles** selon résolution image
- **Intégrer la variabilité spatiale** (aller un peu partout)
- **Intégrer la variabilité des classes** : plusieurs parcelles par classe (selon hétérogénéité de la classe : ~ 5 à 20)
- Choisir des **échantillons indépendants**

Echantillonnage stratifié



Exemple d'échantillonnage stratifié



Segment renseigné
après l'enquête
de terrain

- 1 : Blé
- 2 : Prairie
- 3 : Colza
- 4 : Maïs

Faut-il corriger radiométriquement les images ?

- Interprétation visuelle

→ Non

- Classification numérique

Entraînement basé sur :

- ✓ Observation visuelle terrain

→ Non ! image brute ok

- ✓ Mesures spectrales (BD de signatures ou mesures radiométriques de terrain (ex CROSPCAN)

→ Oui ! reflectance nécessaire

- ✓ Analyse temporelle « déterministe » (profil NDVI)

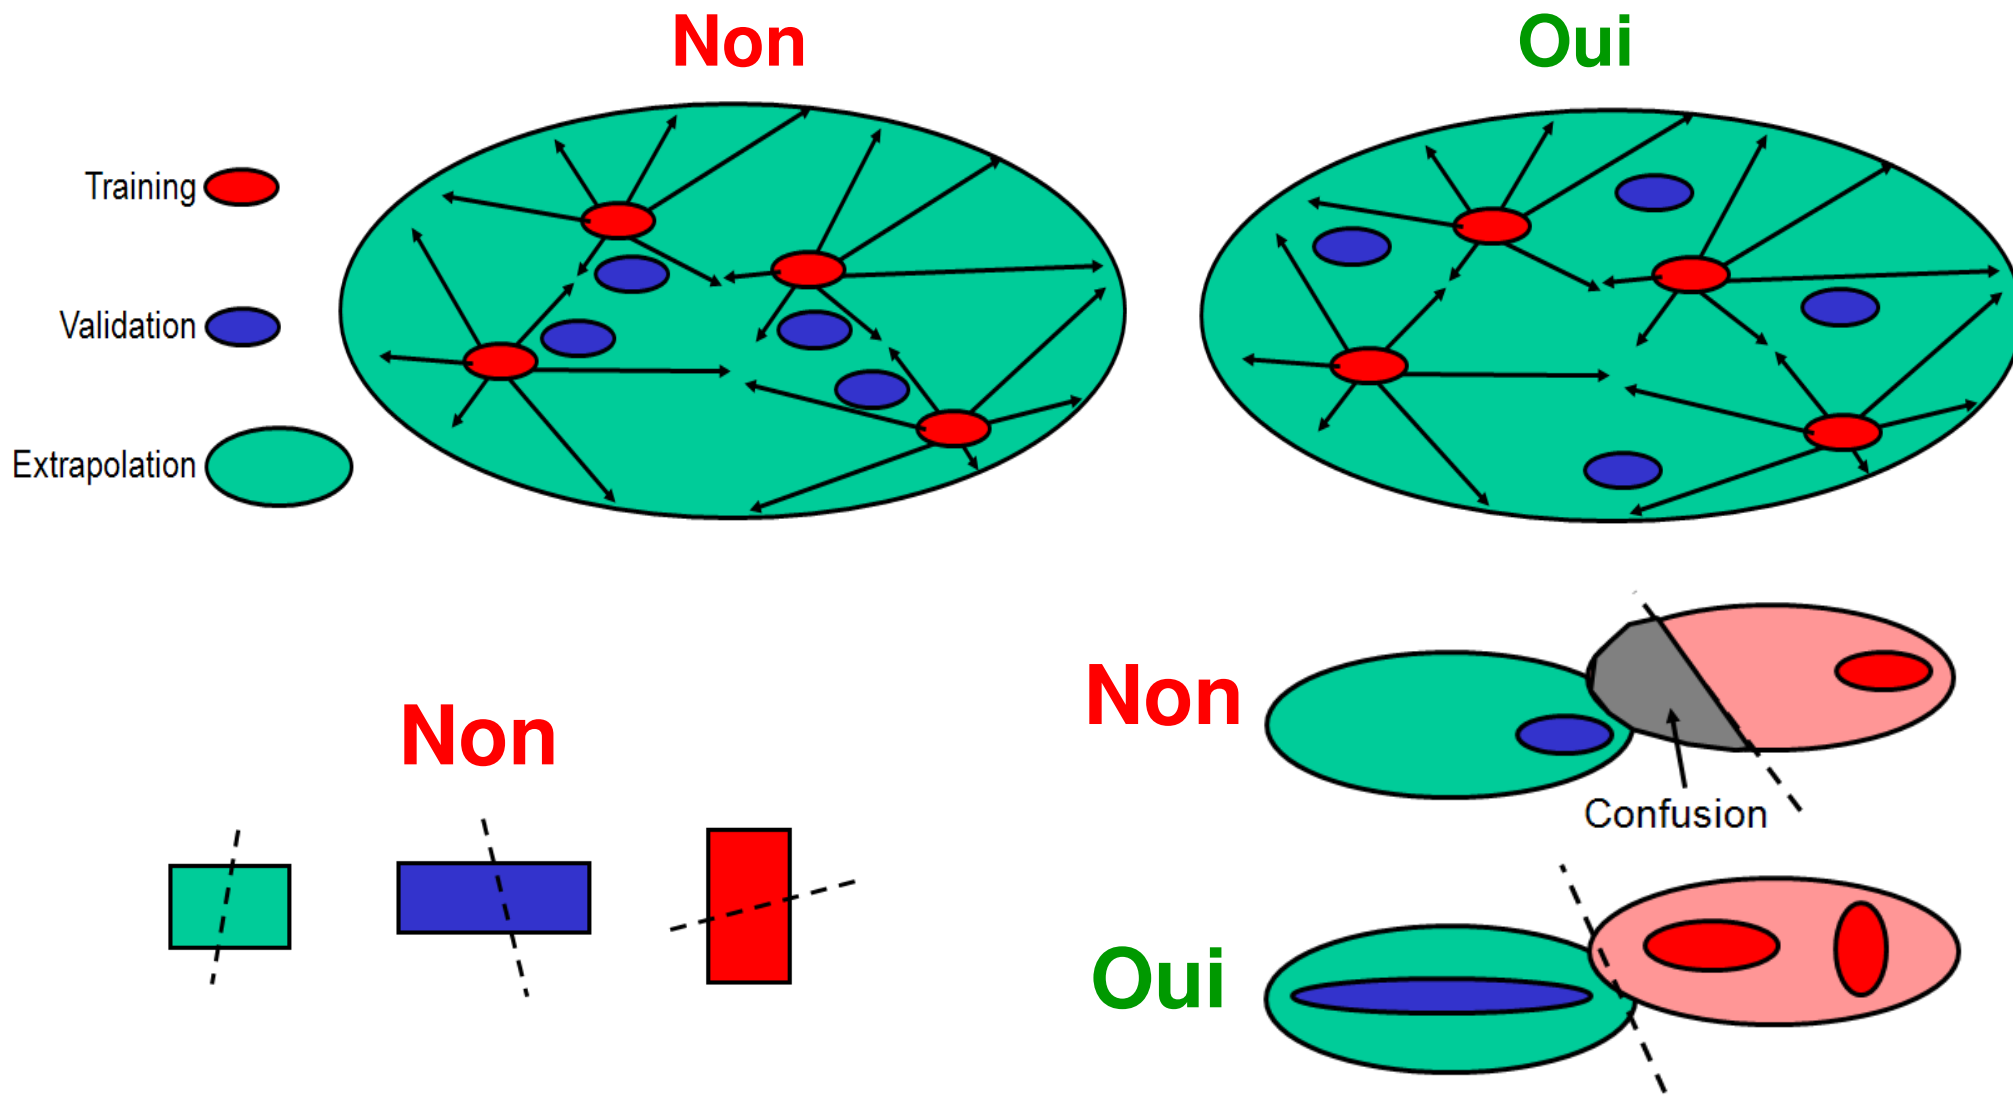
→ Oui ! Dates comparables

Méthodes de classification

Validation d'une classification

Données d'entraînement et de validation doivent être indépendantes

L'entraînement fournit des hypothèses, la classification extrapole sur cette base
=> On ne peut pas valider l'extrapolation à partir de l'hypothèse.



Validation d'une classification

Validation d'une classification

Matrice de confusion

Classement Réalité	Classe 1	...	Classe j	...	Classe c	Totaux
Classe 1	n_{11}		n_{1j}		n_{1c}	n_{1+}
...						
Classe i	n_{i1}		n_{ij}		n_{ic}	n_{i+}
...						
Classe c	n_{c1}		n_{cj}		n_{cc}	n_{c+}
Totaux	n_{+1}		n_{+j}		n_{+c}	N

La proportion de pixels correctement classés est :

$$P_{cc} = \sum_{1,c} (n_{ij} / N)$$

Pour une classe i :

n_{ij} / n_{i+} est la précision « du point de vue du **producteur** », proportion de la classe i réelle effectivement classés en i.

n_{ij} / n_{+j} est la précision « du point de vue de **l'utilisateur** » (qui ne voit que ce qui est classé), proportion de la classe i classée appartenant effectivement à i en réalité.

Validation d'une classification

Validation d'une classification

Matrice de confusion

Classement Réalité	Classe 1	...	Classe j	...	Classe c	Totaux
Classe 1	n_{11}		n_{1j}		n_{1c}	n_{1+}
...						
Classe i	n_{i1}		n_{ij}		n_{ic}	n_{i+}
...						
Classe c	n_{c1}		n_{cj}		n_{cc}	n_{c+}
Totaux	n_{+1}		n_{+j}		n_{+c}	N


- **Le coefficient kappa**

donne un écart au tirage aléatoire

Kappa = 0 pour classification aléatoire (alors que $P_{cc} > 0$)

Kappa = 0,75 => 75% des pixels ne sont pas classés au hasard

$$K = \frac{\sum_{1,c} [N * (n_{ij}) - (n_{+i} * n_{i+})]}{N^2 - \sum_{1,c} (n_{+i} * n_{i+})}$$




1 pixel = { classes }

1 pixel = { classes }

Le pixel est grand par rapport au modèle d'occupation du sol considéré

Exemple :

Menzel Habib Test area (Southern Tunisia)



Classes = « éléments purs » = « End members »

Hypothèse

« *La signature spectrale d'un pixel est la combinaison linéaire des signatures des classes, pondérées par leur abondance relative au sein du pixel* »

=> simplificatrice car pas d'effets latéraux ...

Méthodes



- Régressions sur information spectrale

- Déconvolution spectrale (« Unmixing »)



A partir de la connaissance de **N bandes** spectrales, on peut estimer les abondances de **N+1 classes** dans chaque pixel.

=> résolution d'un système d'équations linéaires



1 pixel = { classes }



Vegetation



Sand




Soil crust

=> % de
recouvrement de
chaque classe
dans le pixel

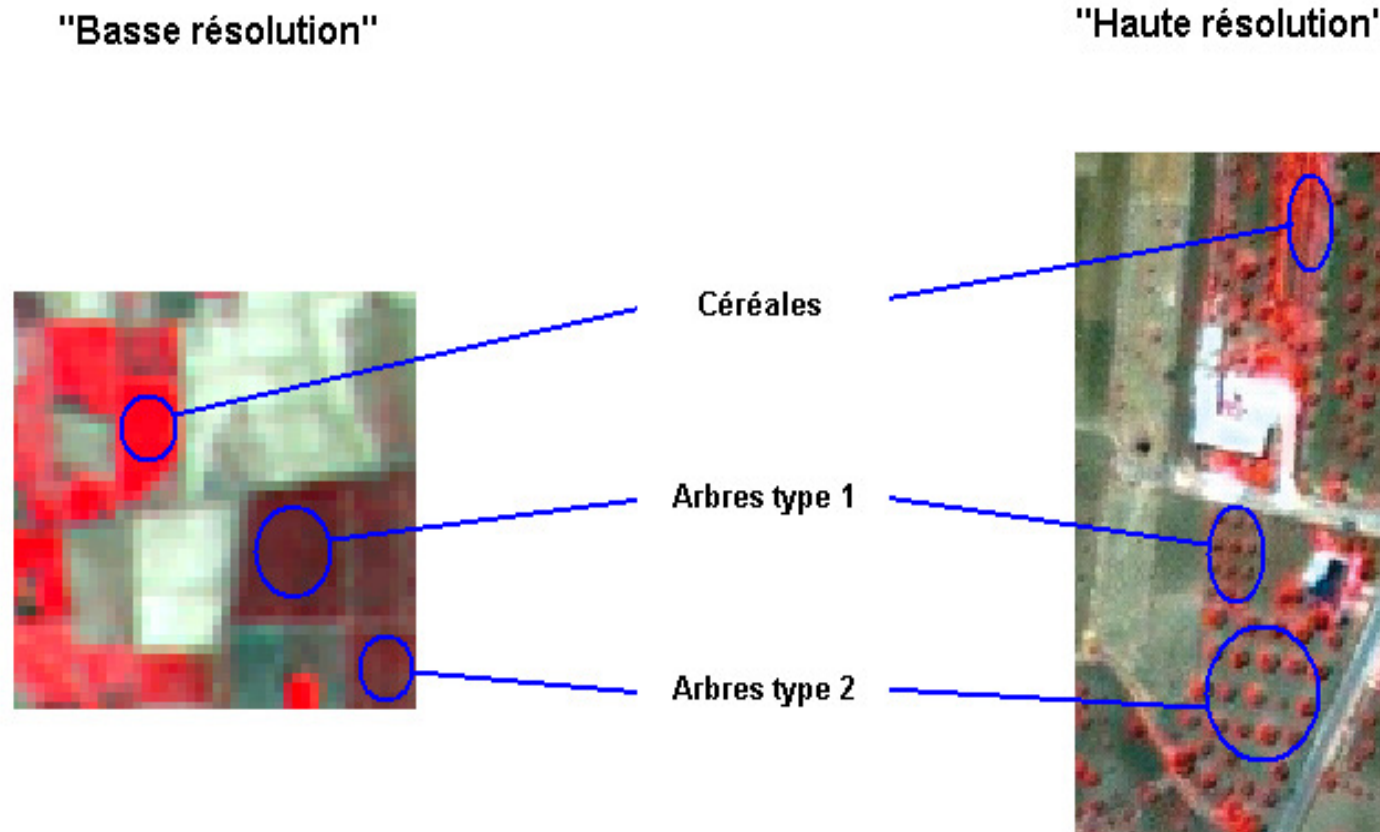
Limitations

- **Nombre de classes limité** au nombre de bandes spectrales indépendantes
- **Grande sensibilité** au choix des signatures des classes
=> test et validation indispensables sur données terrain



1 classe = { pixels }

Le pixel est très petit par rapport au modèle d'occupation du sol considéré



=> il donne accès à des niveaux inférieurs : {canopée éclairée, canopée à l'ombre, sol, adventices} ... pas nécessairement signifiants thématiquement

Potentiellement très intéressant

=> Information spectrale + **structure spatiale**

Développement probable associé aux images THRS (QuickBird, Ikonos...)

Mais...

En général interprétation visuelle

Des outils spécifiques existent



=> Analyse de la composition statistique et / ou spatiale d'un voisinage.

Ex :


- « Texture », souvent simple bande supplémentaire
- OASIS (M.C. Girard (et Mougenot !), 1991)
- CLAPAS (J.M. Robbez Masson) + EPI (LISAH)
- eCognition

1 classe = { pixels }

CLAPAS (J.M. Robbez Masson)




Pentes du Caroux (classes)



1 classe = { pixels }

CLAPAS (J.M. Robbez Masson, 1994)



=> prise en compte du seul environnement statistique,
pas de la disposition des classes

1 classe = { pixels }


Détection d'arbres sur image SPOT 2.5 m

Marrakech - Using Olicount Software (© JRC ISPRA)



1 classe = { pixels }





Détection d'arbres sur image SPOT 2.5 m



*Agrégation avec
opérateurs de
morphologie
mathématique*


→ fermeture + ouverture

Validation

-  Arbres
-  Arbres classés sol
-  Sol
-  Sol classé arbres

Compléments

Objet et résolution spatiale



Niveau d'organisation :
J – homogène
H – hétérogène

(Puech et al. 1995)

Input data preparation

Principal component analysis

What is PCA ?

Calculation of n new axes from n initial spectral axes, which *carry most of the inertia* of the scatter

⇒ It produces *images with high contrast*, because the information is carried on the first axes.

⇒ It may *help classification algorithm* to separate class scatters (but good algorithms shouldn't need this help...)

Example in 2 dimensions

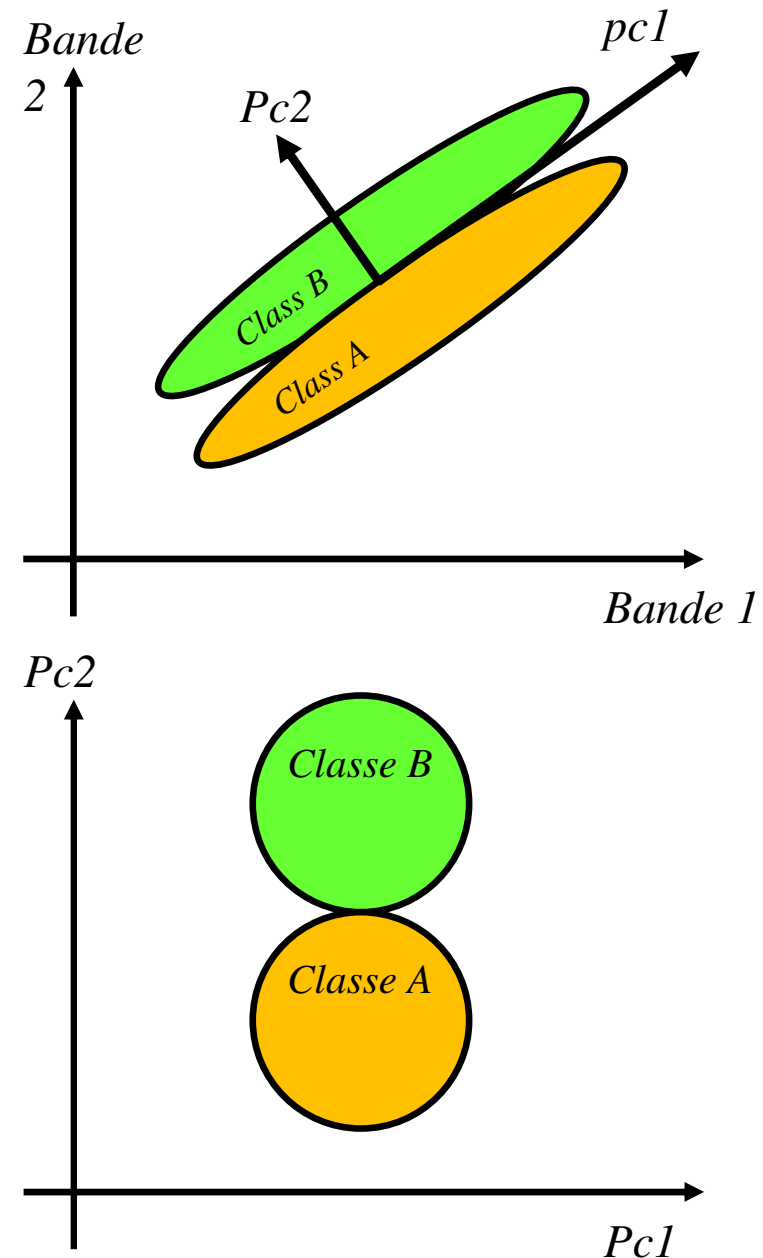


Photo-interprétation manuelle

Fusion multirésolution

*MS 432 (upper left):
4-metre resolution.
PAN (lower left) and Pan-
sharpened (right): 1-metre
resolution.*





Photo-interprétation manuelle

Interprétation visuelle

Prise en compte de :

- **Forme** (ex : parcelle agricole)
- **Structure** (chorologie)
(ex : végétations de type A et B proche dans l'espace car B est un faciès de dégradation de A)
- **Texture** (ex : canopées forestières)....On tend alors vers le cas 1 classe = { pixels }

Checker-shadow illusion:
The squares marked A and B
are the same shade of gray.



Analyse diachronique

Criteria for NDVI profile discrimination


Conditions on NDVI Values	Conditions on NDVI Dynamic	Class
All NDVI < 0.18	No	→ bare soil
Some NDVI > 0.18 and Some NDVI < 0.18	No	→ herbaceous crops
All NDVI > 0.18	Max – Min < 0.15 and All NDVI < 0.45	→ trees on bare soil
	Max – Min > 0.15 or All NDVI > 0.45	→ trees + herbaceous crops

The combinaison of these criteria gives the 4 main Landcover classes

=> These criteria are insensitive to temporal shifts

Estimateur de regresssion

Only to improve **statistical area estimation (crop % cover)**
May the classified image improve the crops % assesment from field survey ?



→ if R^2 is good, the image allows reducing the variance of field survey estimation

1 classe = { pixels }

Aggregation of elementary objects

Semantic and spatial relations

⇒ Taking into account the neighbourhood + radiometry + shape...

Segmentation - Niveau 1



1 classe = { pixels }

Segmentation - Niveau 4



The methods – Summary

- Visual analysis

Deals with spectral confusions in taking account the spatial context at all level, from close neighbourhood level (texture) to the whole landscape analysis

- Texture / landscape analysis

eg : CLAPAS, OASIS, ...

⇒ classification based on class distribution analysis over a large neighbourhood

- Single objects aggregation

Using semantic rules (object A close to object B = object C)

Morphological operators, e.g. aggregation of plantation from trees.