

Classification d'images hyperspectrales par des méthodes fonctionnelles non-paramétriques

A. Zullo^{1,2}, M. Fauvel¹ et F. Ferraty²

¹ Laboratoire DYNAFOR - UMR 1201 - INRA & INP Toulouse, France

² Institut de Mathématiques de Toulouse, France

3^e colloque scientifique du groupe thématique Hyperspectral de la SFPT
15 et 16 mai 2014



Thèse cofinancée par le CNES et la région Midi-Pyrénées

Sommaire

Problématique

Méthodes mises en œuvre en grande dimension

Méthodes non-paramétriques fonctionnelles

Données et résultats

Conclusions et perspectives

Problématique

Méthodes mises en œuvre en grande dimension

Méthodes non-paramétriques fonctionnelles

Données et résultats

Conclusions et perspectives

Problématique

- Échantillonnage spectral de plus en plus fin (augmentation de la quantité et de la qualité de l'information disponible)
- Applications dans de nombreux domaines (écologie, géologie, hydrologie, agriculture de précision, applications militaires, ...)

La classification devient cependant plus difficile car les méthodes conventionnelles sont mises en défaut par :

- Grande dimension spectrale (nombre important de longueurs d'ondes)
- Volume de données important
- Fortes corrélations des bandes spectrales adjacentes

Problématique

Méthodes mises en œuvre en grande dimension

Méthodes non-paramétriques fonctionnelles

Données et résultats

Conclusions et perspectives

Méthodes mises en œuvre en grande dimension

■ Méthodes "génératives" :

- ▶ Extraction de caractéristiques
- ▶ Estimateurs à noyaux
- ▶ **Modèles de Mélanges Gaussiens (GMM)**

■ Méthodes "discriminatives" :

- ▶ Forêts aléatoires (Random Forest)
- ▶ **Séparateurs à Vaste Marge (SVM)**

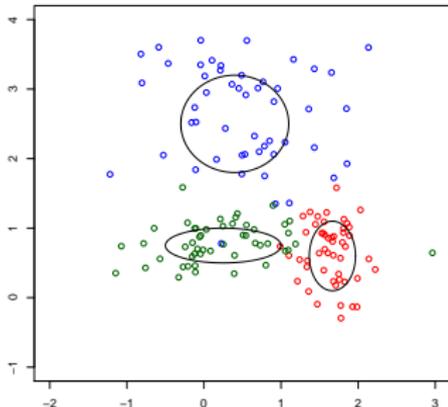
Modèles de Mélanges Gaussiens (GMM)

■ Principe de la méthode :

- ▶ Modélisation des hyperspectres de réflectance des pixels en lois gaussiennes multidimensionnelles

■ Inconvénients majeurs (liés au grand nombre de bandes spectrales) :

- ▶ Estimation de la matrice de covariance et de son inverse (calcul du déterminant, des valeurs et vecteurs propres)
- ▶ Croissance quadratique du nombre de paramètres à estimer



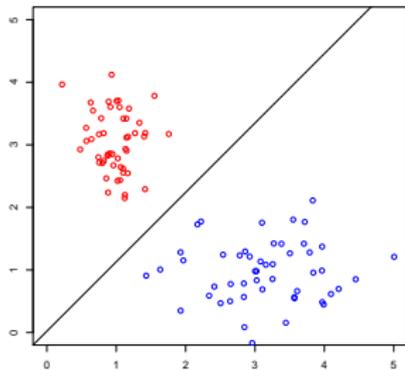
Séparateurs à Vaste Marge (SVM)

■ Principe de la méthode :

- ▶ Recherche d'un hyperplan séparant les hyperspectres en deux groupes (classifieur binaire)
- ▶ Maximisation de la distance à l'hyperplan des hyperspectres les plus proches de chaque classe
- ▶ Classification non-linéaire facilitée par l'utilisation d'une fonction noyau (Kernel trick)

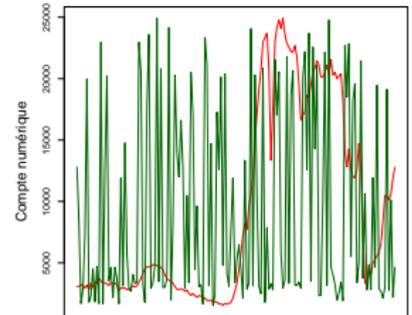
■ Inconvénients majeurs :

- ▶ Hyperspectres non nécessairement linéairement séparables
- ▶ Pas de méthode multinomiale directe (agrégation de classifieurs binaires)
- ▶ Difficultés d'interprétation des paramètres



Problèmes non résolus par ces méthodes

- Prise en compte de l'ordre des bandes spectrales
- Nombre important de bandes spectrales ("Fléau de la dimension")
- Fortes corrélations des bandes spectrales adjacentes
- Nature continue des hyperspectres



Problématique

Méthodes mises en œuvre en grande dimension

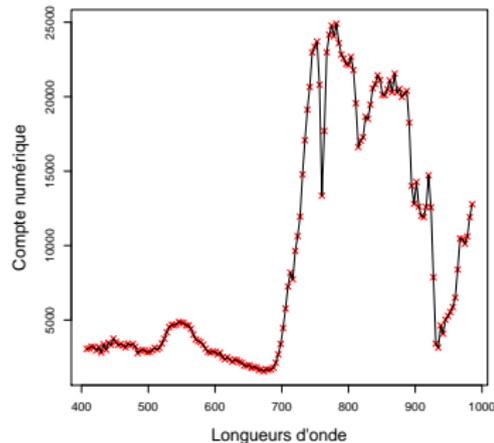
Méthodes non-paramétriques fonctionnelles

Données et résultats

Conclusions et perspectives

Méthodes non-paramétriques fonctionnelles

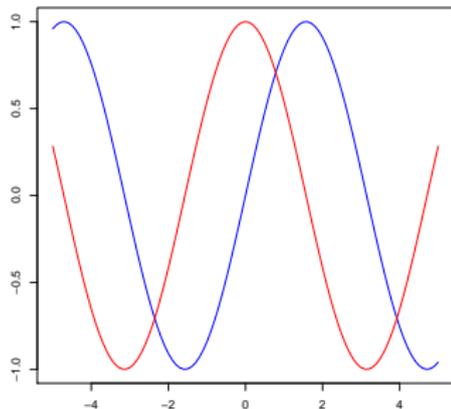
- Prise en compte de la nature "fonctionnelle" des hyperspectres (continuité, ordre des bandes spectrales, corrélations)
- Modélisation de relations non-linéaires entre les hyperspectres et les classes
- Trois paramètres à régler :
 - ▶ La fonction noyau K (influence négligeable)
 - ▶ Son paramètre de d'échelle h (validation croisée)
 - ▶ **La mesure de proximité d**



Le choix de la mesure de proximité d

- Restriction à des familles de pseudo-métriques (réduction de la dimension de l'espace fonctionnel)
 - ▶ Une extension fonctionnelle de la distance L^2 vectorielle standard
 - ▶ Une mesure basée sur une décomposition fonctionnelle en composantes principales (FPCA)
 - ▶ Une mesure basée sur une décomposition multiple des moindres carrés partiels (MPLSR)

$$d(x, y) = 0 \not\Rightarrow x = y$$



Les pseudo-métriques (1)

- La pseudo-métrique L^2 :
 - ▶ Extension fonctionnelle de la distance L^2 vectorielle standard (les sommes deviennent des intégrales)
 - ▶ Décomposition des hyperspectres dans une base de fonctions splines de lissage (stabilisation numérique)
 - ▶ Pas de réduction de la dimension de l'espace fonctionnel

$$d^{L^2}(\mathcal{X}, \mathcal{X}') = \sqrt{\int_{\Lambda} (\mathcal{X}(\lambda) - \mathcal{X}'(\lambda))^2 d\lambda}$$

Les pseudo-métriques (2)

■ La pseudo-métrique FPCA :

- ▶ Décomposition des hyperspectres dans la base des fonctions propres d'une Analyse en Composantes Principales (PCA)
- ▶ Aucun lissage nécessaire
- ▶ Deux paramètres à régler : les indices de la première et la dernière fonctions propres à considérer dans la base

En pratique, on constate que la première fonction propre n'est quasiment jamais prise en compte (albedo moyen non discriminatif)

■ La pseudo-métrique MPLSR :

- ▶ Décomposition des hyperspectres dans la base des fonctions propres d'une Régression Multiple des Moindres Carrés Partiels (MPLSR)
- ▶ Aucun lissage nécessaire
- ▶ Un paramètre à régler : le nombre de composantes à considérer dans la base

Problématique

Méthodes mises en œuvre en grande dimension

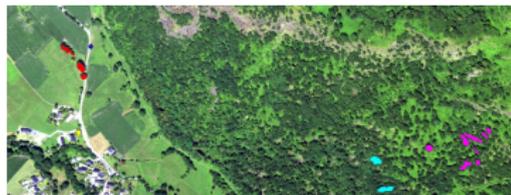
Méthodes non-paramétriques fonctionnelles

Données et résultats

Conclusions et perspectives

Présentation des données étudiées

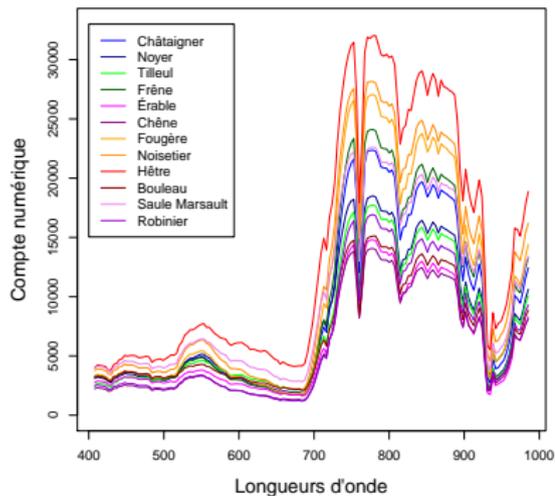
- Caractérisation du frêne par télédétection hyperspectrale
- 12 classes (espèces arborées) pour un total de 32224 pixels
- Capteur de type HYSPEX (160 bandes spectrales de 400 à 1000 nm)



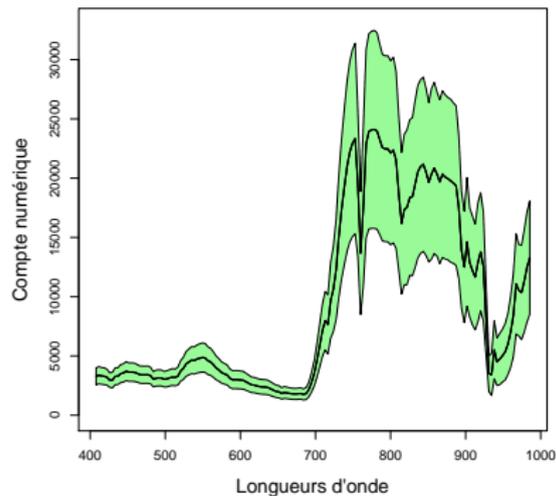
Espèce arborée	Châtaignier	Noyer	Tilleul	Frêne
Nombre de pixels	2855	1016	3402	4333
Espèce arborée	Érable	Chêne	Fourgère	Noisetier
Nombre de pixels	165	10981	1983	4122
Espèce arborée	Hêtre	Bouleau	Saule Marsault	Robinier
Nombre de pixels	42	468	485	2372

Premières observations

Hyperspectres moyens



Hyperspectre moyen + ou - la déviation standard du frêne

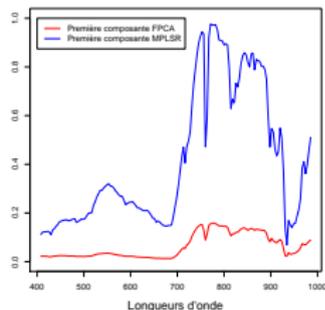


Protocole expérimental

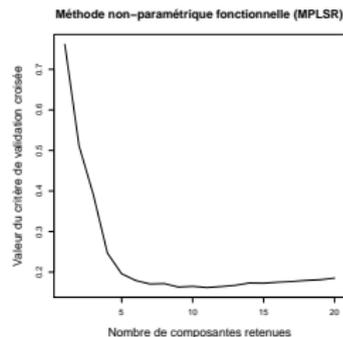
- Classification supervisée :
 - ▶ Échantillon d'apprentissage : 30 pixels par espèce (360 pixels au total)
 - ▶ Échantillon-test : tous les autres pixels (soit 31864 pixels)
- Validation du modèle à l'aide d'un critère d'erreur de prédiction (taux de mauvaise classification sur l'échantillon-test)
- 50 répétitions indépendantes

Optimisation des paramètres

- Optimisation de tous les paramètres par validation croisée



- Fonctions propres retenues (en moyenne) :
 - ▶ De la 2^e à la 9^e composante FPCA
 - ▶ Les 12 premières composantes MPLSR



Principaux résultats

■ Classification globale (12 espèces)

Modèle	GMM	SVM	Non-paramétrique fonctionnel		
Pseudo-métriques			L^2	FPCA	MPLSR
Erreurs de classification	15,75%	14,13%	53,05%	29,42%	12,96%

■ Discrimination du frêne

Modèle	GMM	SVM	Non-paramétrique fonctionnel		
Pseudo-métriques			L^2	FPCA	MPLSR
Erreurs d'excédents	23,82%	29,54%	83,30%	54,09%	28,38%
Erreurs de déficits	31,03%	16,39%	54,84%	27,51%	6,27%

Problématique

Méthodes mises en œuvre en grande dimension

Méthodes non-paramétriques fonctionnelles

Données et résultats

Conclusions et perspectives

Conclusions

- Bonne classification des espèces arborées par leurs hyperspectres
- Meilleurs résultats obtenus pour MPLSR face à L^2 et FPCA dans le cadre de la méthode non-paramétrique fonctionnelle
- Légère amélioration des résultats observés pour la méthode non-paramétrique fonctionnelle (MPLSR) face aux méthodes conventionnelles (GMM et SVM)

Perspectives

- Débruitage des données à l'aide d'un lissage
- Sélection de bandes spectrales
- Étude des corrélations spatiales