



Analyse de textures hyperspectrales par Champ de Markov Gaussien

**Guillaume Rellier¹, Xavier Descombes¹,
Frédéric Falzon², Josiane Zerubia¹**

¹ projet ARIANA, CNRS/INRIA/UNSA
INRIA Sophia-Antipolis

²Alcatel Space, Cannes

PLAN

- Introduction
- Modèle markovien gaussien de texture
- Description de l'algorithme de classification
- Pré-traitement : Extraction de caractéristiques radio-métriques
- Pré-traitement : Extraction de paramètres de texture
- Classification
- Résultats
- Conclusion & Perspectives

Introduction

- **Cadre : analyse de texture, en particulier l'analyse des zones urbaines**

- **Méthode : exploiter les données hyperspectrales de façon à tirer parti de :**
 - un **plus grand nombre de bandes spectrales** que dans les images multispectrales classiques,
 - **l'information inter-bande.**

- **Données : images du capteur aéroporté AVIRIS (JPL) :**
 - Airborne Visible/InfraRed Imaging Spectrometer
 - résolution \sim **20m**
 - **224 bandes**

CONTENU

- ✓ ● Introduction
- ⇒ ● Modèle markovien gaussien de texture
 - Des outils d'analyse de texture
 - Champs de Markov
 - Champ de Markov gaussien
 - Champs Markovien gaussien Multivarié
 - Simplification du modèle
 - Estimation des paramètres
- Description de l'algorithme de classification
- Pré-traitement : Extraction de caractéristiques radiométriques
- Pré-traitement : Extraction de paramètres de texture
- Classification
- Résultats
- Conclusion & Perspectives

2 Modèle markovien gaussien de texture

Des outils d'analyse de texture

- Paramètres caractéristiques extraits des **matrices de co-occurrence** (Haralick).
 - Analyse scalaire \Rightarrow l'information inter-bande n'est pas prise en compte.
- **Analyse en ondelettes** : même remarque
- **Filtrage de Gabor** : banc de filtres orientés, consistant en une onde plane sinusoïdale modulée par une gaussienne.
 - Information inter-bande pas prise en compte.
 - Peu efficace en analyse urbaine
- Champs de Markov

Les champs de Markov peuvent être facilement adaptés aux **données multivariées**.

3 Modèle markovien gaussien de texture

Champs de Markov

L'image est considérée comme la réalisation d'un champ aléatoire $X = \{X_s\}_{s \in S}$, où S est l'ensemble des sites de l'image (les pixels).

Le champ X est un champ de Markov si et seulement si :

$$P(X_s = x_s / X^s = x^s) = P(X_s = x_s / \{x_t\}, t \in V_s)$$

Cette **modélisation contextuelle** est utilisée en :

⇒ **régularisation**

– Modèle d'Ising, Potts, Chien-Modèle

⇒ **modélisation de texture**

– Modèle auto-binomial, Derin-Elliott

4 Modèle markovien gaussien de texture

Champ de Markov gaussien

Modèle utilisé pour l'**analyse urbaine** en imagerie monospectrale (**1 dimension**).

$$P(x_s / \{x_t\}, t \in V_s) = \frac{1}{Z} \exp \left(-\frac{(x_s - \sum_t \alpha_t x_t)^2}{2\sigma^2} \right)$$

Adaptation aux données multispectrales :

- Variables **scalaires**, champ **3D**

$$X = \{X_{i,j,k}\} \text{ avec } \begin{cases} 0 \leq i < N_h \\ 0 \leq j < N_v \\ 0 \leq k < N_c \end{cases}$$

- Variables **vectérielles**, champ **2D**

$$X = \{X_{i,j}\} \text{ avec } \begin{cases} 0 \leq i < N_h \\ 0 \leq j < N_v \\ X_{i,j} = (X_{i,j,0}, \dots, X_{i,j,N_c-1})^t \end{cases}$$

Champs Markovien gaussien Multivarié

MGMRF : *Multivariate Gaussian Markov Random Field.*

$$P(x_s | \{x_t\}, t \in V_s) = \frac{1}{Z} \exp \left\{ -\frac{1}{2} \left\| x_s - \sum_{t \in V_s} \theta_{t-s} x_t \right\|_{\Sigma}^2 \right\}$$

où $\|a\|_{\Sigma}^2 = a^t \Sigma^{-1} a$, et Σ est appelée matrice de covariance conditionnelle.

Ceci est équivalent à la formulation globale suivante :

$$P(x) = \frac{1}{Z(S)} \exp \left(-\frac{1}{2} x^t \left(I_{N_h} \otimes I_{N_v} \otimes \Sigma^{-1} \right) A x \right) \quad (1)$$

où la structure de A est déterminée par les paramètres d'interaction θ_t de façon à ce que $Ax = u$, où u est l'erreur d'estimation.

Simplification du modèle

La simplification est due à la **grande dimension spectrale** de l'espace initial.

Les problèmes rencontrés sont :

- **des temps de calcul élevés,**
- **une mauvaise précision des estimations statistiques.**

Dans les **espaces de grande dimension**, le nombre d'échantillons nécessaires pour effectuer une bonne estimation des paramètres statistiques est très grand : c'est la malédiction de la dimension (**phénomène de Hughes**).

⇒ hypothèse sur la **structure des matrices** θ_t :

$$\theta_t = \text{diag}(a_t) = a_t I_N$$

Nouvelle expression de la probabilité conditionnelle :

$$P(x_s | \{x_t\}, t \in V_s) = \frac{1}{Z} \exp \left\{ -\frac{1}{2} \left\| x_s - \sum_{t \in V_s} a_{t-s} x_t \right\|_{\Sigma}^2 \right\}$$

Estimation des paramètres

Méthodes d'estimation de $\phi = (\{a_t\}, \Sigma)$

- **Estimateur du Maximum de Vraisemblance :**

$$\hat{\phi} = \arg \max_{\phi} (P(x/\phi))$$

Optimisation par une méthode numérique : e.g. gradient.

- **Estimateur du Maximum de Pseudo-Vraisemblance :**

Hypothèse de Pseudo-Vraisemblance :

$$P(x) \approx \prod_{s \in \Omega} P(x_s | \{x_t\}, t \in V_s)$$

Optimisation approchée par résolution d'un système matriciel de dimension égale au nombre de paramètres d'interaction.

CONTENU

- ✓ ● Introduction
- ✓ ● Modèle markovien gaussien de texture
- ⇒ ● Description de l'algorithme de classification
 - Pré-traitement : Extraction de caractéristiques radio-métriques
 - Pré-traitement : Extraction de paramètres de texture
 - Classification
 - Résultats
 - Conclusion & Perspectives

8 Description de l'algorithme de classification

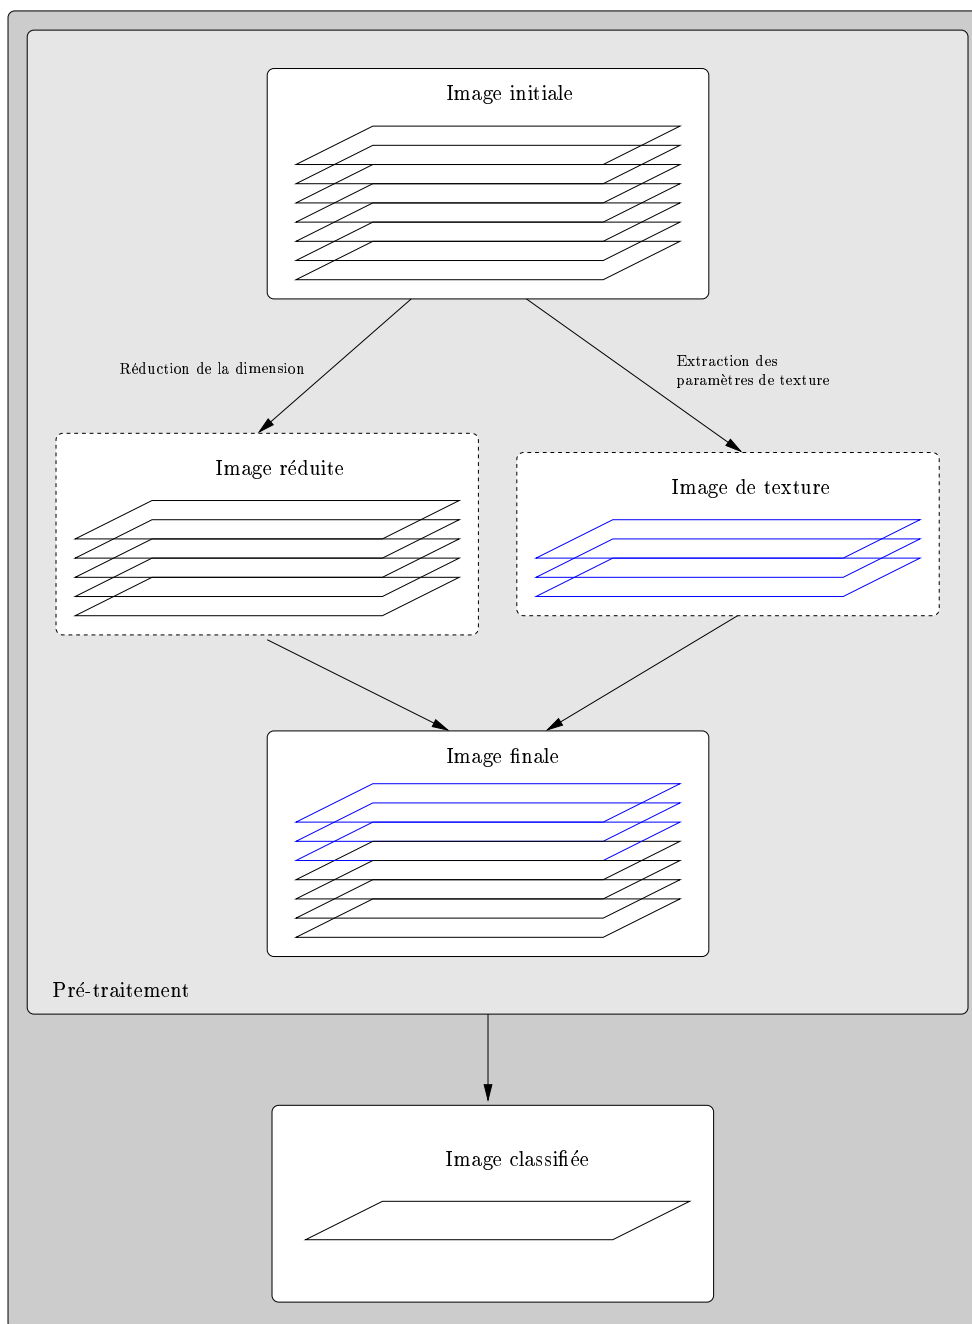


FIG. 1 – L'algorithme de classification.

CONTENU

- ✓ ● Introduction
- ✓ ● Modèle markovien gaussien de texture
- ✓ ● Description de l'algorithme de classification
- ⇒ ● Pré-traitement : Extraction de caractéristiques radio-métriques
 - Extraction de caractéristiques
 - Poursuite de projection
- Pré-traitement : Extraction de paramètres de texture
- Classification
- Résultats
- Conclusion & Perspectives

9 Pré-traitement : Extraction de caractéristiques radiométriques

Extraction de caractéristiques

■ Besoin de réduction de dimension des données

Phénomène de Hughes :

Effectuer des **estimations statistiques de paramètres** dans un espace de **grande dimension** donne des **résultats peu robustes**.

⇒ **Réduction de la dimension de l'espace**, par une projection linéaire des données dans un **“bon” sous-espace**.

■ Justification :

- La **redondance** entre les bandes implique que la perte d'information due à une bonne projection est faible,
- Des **propriétés géométriques** des espaces de grande dimension : nuages de points dans des sous-espaces, les projections linéaires “normalisent” les distributions,
- Moins de calculs, moins de données à traiter.

10 Pré-traitement : Extraction de caractéristiques radiométriques

Poursuite de projection

Principe (Huber 85) :

Famille générale de méthodes dont le but est de trouver un sous-espace dans lequel un **indice de projection** est **optimisé**.

Interêt :

- Le problème de la **dimension** est **limité** car tous les calculs sont faits dans le **sous-espace de projection**,
- L'**indice de projection** peut être **adapté** selon le traitement visé : classification, compression, bonne description du signal.

Problèmes :

- Selon la mise en œuvre: le **temps de calcul** est **assez élevé** quand la recherche est effectuée itérativement,
- Comme les méthodes classiques (ACP, LDA), la **projection est linéaire**, et peut ne pas bien refléter des données à la structure très “non-linéaire”.

11 Pré-traitement : Extraction de caractéristiques radiométriques

Poursuite de projection (suite)

■ Algorithmes

- **Poursuite de projection paramétrique séquentielle** (Jimenez & Landgrebe 99)
- **Poursuite de projection paramétrique parallèle** (Jimenez & Landgrebe 99)
- **Croissance/Décroissance d'espace**

■ Indice de projection

Dans un algorithme de classification par MV : **Une borne supérieure** de la probabilité d'erreur est une fonction de la **distance de Bhattacharyya**.

⇒ utilisation de la **distance de Bhattacharyya** comme **indice de projection**.

$$B_{12} = \frac{1}{8} \|\mu_1 - \mu_2\|_{\Sigma_{12}} + \frac{1}{2} \ln \left(\frac{|\Sigma_{12}|}{\sqrt{|\Sigma_1| |\Sigma_2|}} \right) \quad (2)$$

CONTENU

- ✓ ● Introduction
- ✓ ● Modèle markovien gaussien de texture
- ✓ ● Description de l'algorithme de classification
- ✓ ● Pré-traitement : Extraction de caractéristiques radio-métriques
- ⇒ ● Pré-traitement : Extraction de paramètres de texture
 - Choix des paramètres de texture
 - Distribution des paramètres de texture
 - Réduction de dimension
- Classification
- Résultats
- Conclusion & Perspectives

12 Pré-traitement: Extraction de paramètres de texture

Choix des paramètres de texture

Les paramètres du modèle de texture sont :

- Les **paramètres d'interaction** a_t ,
- La **matrice de covariance conditionnelle** Σ .




FIG. 2 – a) Extrait de 3 bandes visibles de l'image AVIRIS de Moffett Field, b) variance conditionnelle σ extraite d'une bande de cette image, c) paramètres d'interaction a extrait d'une bande de cette image.

⇒ **utilisation de Σ** pour former de nouvelles images.

13 Pré-traitement : Extraction de paramètres de texture

Distribution des paramètres de texture

La **distribution** des paramètres de texture n'est **pas normale**.




FIG. 3 – histogramme du paramètre σ calculé sur 1 bande de l'image AVIRIS de Moffett Field, pour 2 zones urbaines.

⇒ approximation de la distribution de Σ par une **distribution de Wishart** dont les 2 premiers moments sont les mêmes.

Pourquoi Wishart ?

C'est la distribution de la **matrice de covariance empirique**.

14 Pré-traitement : Extraction de paramètres de texture

Réduction de dimension

Comme pour l'extraction de caractéristiques radiométriques :

- **Poursuite de projection** : croissance d'espace
- **Indice de projection** : Distance de Bhattacharyya

■ Distance de Bhattacharyya :

Soit Σ_1 et Σ_2 deux matrices de dimension $p \times p$ tels que :

- $n_1 \Sigma_1$ suit une distribution de Wishart de paramètres (S_1, n_1)
- $n_2 \Sigma_2$ suit une distribution de Wishart de paramètres (S_2, n_2)

Le distance de Bhattacharyya entre ces deux distributions est :

$$B_{12} = \frac{n_1^{\frac{pn_1}{4}} n_2^{\frac{pn_2}{4}} |\Sigma_{12}|^{\frac{n_1+n_2}{4}}}{|\Sigma_1|^{\frac{n_1}{4}} |\Sigma_2|^{\frac{n_2}{4}}} \quad (3)$$

$$\text{où } \Sigma_{12}^{-1} = \frac{1}{2} (n_1 \Sigma_1^{-1} + n_2 \Sigma_2^{-1}).$$

CONTENU

- ✓ ● Introduction
- ✓ ● Modèle markovien gaussien de texture
- ✓ ● Description de l'algorithme de classification
- ✓ ● Pré-traitement : Extraction de caractéristiques radiométriques
- ✓ ● Pré-traitement : Extraction de paramètres de texture
- ⇒ ● Classification
 - Algorithme de classification
 - Résultats
 - Conclusion & Perspectives

Algorithme de classification

■ Classification par le critère du Maximum de Vraisemblance.

Soient L classes $C_l, l = 0 \dots L-1$. La règle de décision est :

$$\hat{\lambda}_s = \arg \max_{l \in \{0, L-1\}} P_l(x^s) = \arg \max_{l \in \{0, L-1\}} P_l(x_r^s, x_t^s) \quad (4)$$

Hypothèse : independance entre texture et radiométrie.

$$\hat{\lambda}_s = \arg \max_{l \in \{0, L-1\}} P_l(x_r^s) P_l(x_t^s) \quad (5)$$

Partie radiometrie \Rightarrow distribution **gaussienne**.

Partie texture \Rightarrow distribution de **Wishart**.

CONTENU

- ✓ ● Introduction
- ✓ ● Modèle markovien gaussien de texture
- ✓ ● Description de l'algorithme de classification
- ✓ ● Pré-traitement : Extraction de caractéristiques radiométriques
- ✓ ● Pré-traitement : Extraction de paramètres de texture
- ✓ ● Classification
- ⇒ ● Résultats
 - Images de synthèse
 - Comparaisons de classifications
 - Images AVIRIS
- Conclusion & Perspectives

Images de synthèse




FIG. 4 – Données simulées avec différents rapports S/B (gauche), classification (droite).

Comparaisons de classifications

■ ACP-N :

- Réduction de dimension : Analyse en composantes principales,
- Classification : MV, modèle gaussien.

■ PP-N :

- Réduction de dimension : poursuite de projection,
- Classification : MV, modèle gaussien.

■ PPR-N :

- Comme PP-N, avec régularisation par modèle de Potts.

■ PP-NN :

- Réduction de dimension : poursuite de projection,
- Extraction de bandes de texture,
- Classification : MV, modèle gaussien + Wishart.

Images AVIRIS



FIG. 5 – 3 bandes extraites d'une mosaïque de textures urbaines AVIRIS




FIG. 6 – Classification de la mosaïque de textures AVIRIS par trois méthodes différentes. bleu : PP-N , rouge : PPR-N, vert : PP-NN.

Images AVIRIS (suite)




FIG. 7 – 3 bandes extraites d'une sous-image de l'image de Moffett Field.




FIG. 8 – Classification de la sous-image par 4 méthodes différentes. bleu : $PP - N$, rouge : $PP - N$ avec régularisation de Potts, vert : $PP - NN$, turquoise : $ACP - N$.

Conclusion & Perspectives

■ Conclusion

- Méthode d'analyse de texture
- Aspects **spectral et spatial traités conjointement**
- Bons résultats de classification

■ Travaux futurs

- Contours entre textures ?
- Estimation de paramètres plus rapide ?
- Choix de la taille de fenêtre ?
- Détection de plusieurs textures dans une même fenêtre ?