

Un modèle markovien gaussien pour l'analyse de texture hyperspectrale en milieu urbain

Guillaume RELIER¹, Xavier DESCOMBES¹, Frédéric FALZON², Josiane ZERUBIA¹

¹Ariana - projet commun Cnrs/Inria/Unsa
INRIA, 2004 route des Lucioles, BP 93, 06902 Sophia Antipolis Cedex, France

²Alcatel Space Industries
Bd du Midi, BP 99, Cannes la Bocca Cedex, France
Guillaume.Rellier@inria.fr, Xavier.Descombes@inria.fr
Frederic.Falzon@space.alcatel.fr, Josiane.Zerubia@inria.fr

Résumé — Nous considérons ici le problème de l'analyse de texture d'images hyperspectrales. De manière à tirer partie de la finesse de la discrétisation spectrale inhérente à ce type d'image nous réalisons une modélisation de texture conjointe spatiale et spectrale en employant une approche vectorielle dans un modèle markovien. Ce modèle est ensuite testé dans le cadre de la classification de zones urbaines.

Abstract — In this work we tackle the problem of texture analysis on hyperspectral images. In order to perform a global analysis, both spatial and spectral, we use a vectorial approach through a markovian model. This model is used in a classification algorithm aimed at urban area analysis.

1 Introduction

L'analyse de texture fait partie de la panoplie des méthodes d'interprétation d'image. En télédétection, on complète régulièrement l'analyse radiométrique des images par une analyse de texture. Cette dernière se prêtant mieux à la caractérisation/extraction de zones urbaines ou de zones composées d'objets manufacturés. Les travaux qui ont eu lieu dans ce cadre ces dernières années prennent plus particulièrement en compte des images panchromatiques car elles sont toujours mieux résolues que leurs homologues multispectrales. On réalise, en général, une classification fondée sur la radiométrie à partir d'images multispectrales et ensuite on effectue une classification de textures à partir d'une image panchromatique de la même zone. Les cartes thématiques obtenues à l'issue de ces deux classifications sont ensuite fusionnées. Contrairement à l'approche que nous venons de décrire, et dans laquelle l'analyse de texture est réalisée en utilisant des opérateurs uniquement sensibles aux variations locales de contraste, nous allons également prendre en compte les variations spectrales de la texture. Cette analyse de texture sera réalisée à partir d'images hyperspectrales de télédétection. Nous espérons ainsi enrichir la description habituelle des textures qui est uniquement fondée sur la prise en compte des variations locales de contraste.

Dans le paragraphe suivant on décrit un modèle markovien de texture capable de réaliser une telle analyse. Dans le troisième paragraphe, on étudie comment il est possible d'insérer ce modèle dans une méthode de classification d'image hyperspectrale texturée. Quelques résultats sont présentés dans le quatrième paragraphe.

2 Modèle markovien de texture multivariée

Dans le cas de l'analyse conjointe de texture spectrale et spatiale qui nous intéresse ici, on peut montrer que les méthodes classiques d'analyse de texture (matrices de co-occurrences des niveaux de gris [1], transformée de Gabor [2], ...) peuvent difficilement être utilisées. En effet, la complexité algorithmique liée au volume des données mis en jeu dans le cas hyperspectral est rédhibitoire. De plus, il est plus réaliste, dans ce cadre, de construire un opérateur "compact" susceptible de réaliser l'analyse conjointe en espace et longueurs d'ondes et bien adapté au problème de la classification qui demande automatiquement une réduction de la dimension de l'espace d'observation.

L'outil que nous allons développer ici dans le cadre de l'analyse de données multivariées est fondé sur une modélisation par champ de Markov. En effet, la modélisation habituelle des images par ces champs peut être adaptée de deux façons aux données multivariées : en considérant un champ scalaire à trois dimensions (deux spatiales et une spectrale) ou en considérant un champ de vecteurs (la mesure en chaque pixel) à deux dimensions spatiales. Nous nous attachons dans la suite à décrire un tel opérateur d'analyse.

2.1 Modèle markovien gaussien multivarié

Utilisons un modèle du deuxième type : un champ vectoriel à deux dimensions spatiales. On considère donc une image comme un champ $X = \{X_s\}$ où chaque site $s =$

(i, j) est défini par deux coordonnées spatiales. Chaque X_s est un vecteur aléatoire de dimension N_b , le nombre de bandes.

Un champ de Markov X est un champ aléatoire dans lequel la probabilité en un site s conditionnellement au reste du champ est égale à la probabilité en ce site connaissant uniquement ses voisins.

La probabilité conditionnelle d'un champ markovien gaussien multivarié est de la forme :

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

Avec $\|a\|_{\Sigma}^2 = a^t \Sigma^{-1} a$, les θ_i étant des matrices de transformation et Σ la matrice de covariance conditionnelle.

Cette formule peut aussi être écrite en termes de probabilité conditionnellement à des moyennes de voisins :

$$P(x_s|\{m_k\}) = \frac{1}{Z} \exp \left\{ -\frac{1}{2} \left\| x_s - \sum_{k=0}^K \theta'_k m_s^k \right\|_{\Sigma}^2 \right\} \quad (2)$$

où K représente le nombre de types de voisinage V^k (un type de voisinage est un ensemble de pixels voisins qui agissent de la même façon sur le pixel considéré, et qui sont donc pondérés par le même coefficient a), m_s^k est la moyenne des pixels voisins de type k du point x_s considéré, et $\theta'_k = \frac{\theta_{t-s}}{n_k}$, où $t \in V_s^k$ et n_k est le nombre de pixels du voisinage V^k .

Cette formulation est équivalente à une formulation par la loi globale du champ :

$$P(x) = \frac{1}{Z(S)} \exp \left(-\frac{1}{2} x^t S^{-1} x \right) \quad (3)$$

où $S = (I_{N_h} \otimes I_{N_v} \otimes \Sigma^{-1}) A$, \otimes désignant le produit de Kronecker, et A une matrice définie par les interactions θ_i et le voisinage considéré.

2.2 Adaptation aux images hyperspectrales

L'utilisation de ce modèle tel quel pour des images hyperspectrales pose quelques problèmes. En effet, ces images sont caractérisées par un grand nombre de bandes spectrales¹, par conséquent les vecteurs X_s considérés sont de grande dimension. En effet, on montre que l'étude statistique de vecteurs de grande dimension est difficile (voire impossible) en l'absence d'un grand nombre d'échantillons d'apprentissage, c'est le phénomène de Hughes [3].

Une solution consiste à réduire la dimension de l'espace par projection des données dans un sous-espace (comme effectué par la suite). Une autre consiste à réduire le nombre de paramètres du modèle, car la dimensionnalité pénalise la phase d'estimation des paramètres quand ils sont trop nombreux.

On effectue donc une simplification du modèle par ces matrices de transformations θ_i , que l'on considère diagonales (on omet l'indice i correspondant au type de voisinage).

$$\theta' = \text{diag}(a_0, \dots, a_j, \dots, a_{N_b-1}) \quad (4)$$

¹Par exemple, le capteur AVIRIS fournit des images à 224 bandes

Faire cette approximation consiste à considérer que les interactions spatiales se font indépendamment bande par bande.

2.3 Estimation des paramètres

Un problème important dans l'utilisation des champs de Markov est l'estimation de leurs paramètres. Ici, les paramètres à estimer pour chaque texture sont les a_j et les matrices Σ de covariance conditionnelle.

2.3.1 Maximum de vraisemblance

Un critère très utilisé pour l'estimation de paramètres est le critère du Maximum de Vraisemblance (MV). Il consiste à retenir le vecteur de paramètres ϕ (dans la cas présent $\phi = (\{a_k\}, \Sigma)$), tel que :

$$\phi = \arg \max_{\phi} (P(x/\phi)) = \arg \max_{\phi} (\log P(x/\phi)) \quad (5)$$

En utilisant l'équation (3) et en explicitant la constante de normalisation, il vient que le logarithme de la vraisemblance, $LV(\phi)$, peut s'écrire :

$$LV(\phi) = C - \frac{1}{2} \ln |S| - \frac{1}{2} x^t S^{-1} x \quad (6)$$

On peut maximiser cette fonction par des algorithmes numériques, mais le processus peut être relativement lent.

2.3.2 Maximum de pseudo-vraisemblance

Un critère permettant une estimation plus rapide est celui du maximum de pseudo-vraisemblance [4]. Ce critère est fondé sur une hypothèse d'indépendance des probabilités conditionnelles et mène à l'approximation suivante concernant la probabilité du champ x :

$$P(x) \approx \prod_{s \in \Omega} P(x_s|\{x_t\}, t \in V_s) \quad (7)$$

La maximisation de cette fonction se fait par la résolution du système suivant :

$$\begin{pmatrix} \overline{m_j^0 m_j^0} & \dots & \overline{m_j^0 m_j^{K-1}} \\ \vdots & & \vdots \\ \overline{m_j^{K-1} m_j^0} & \dots & \overline{m_j^{K-1} m_j^{K-1}} \end{pmatrix} \begin{pmatrix} a_j^0 \\ \vdots \\ a_j^{K-1} \end{pmatrix} = \begin{pmatrix} \overline{x_j m_j^0} \\ \vdots \\ \overline{x_j m_j^{K-1}} \end{pmatrix} \quad (8)$$

où \overline{m} représente la moyenne de la variable m . Ce système matriciel est résolu pour chaque $j = 0 \dots N_b$.

3 Application à la classification

3.1 Classification

Soit un problème de classification à 2 classes C_0 et C_1 . La règle de décision correspondant au maximum de vraisemblance (MV) est, dans le cas de la modélisation présentée ci-dessus, d'affecter le label $\lambda_s \in \{0, 1\}$ au pixel s de la façon suivante :

$$\lambda_s = \arg \max_{i \in \{0,1\}} P_i(x_s / \{m_s^k\}) \quad (9)$$

Cette règle est extensible à L classes, en choisissant la classe la plus vraisemblable.

Malheureusement, cette règle est très locale et peut donner des classifications très irrégulières, c'est pourquoi on effectue une régularisation par un modèle de Potts.

3.2 Réduction d'espace

Comme expliqué au paragraphe 2.2, les données de grande dimension posent certains problèmes quand il s'agit d'estimer les paramètres statistiques. On a procédé à des simplifications du modèle afin de limiter ces problèmes, mais ils subsistent tout de même en partie, notamment pour l'estimation de la matrice de covariance conditionnelle.

Pour remédier à cela, on effectue en début de traitement une projection des données depuis l'espace original à N_b dimensions dans un sous-espace de dimension réduite.

On utilise pour cela une méthode de poursuite de projection paramétrique [5] adaptée au modèle présenté [6]. Cet algorithme consiste à rechercher par optimisation numérique un sous-espace dans lequel un certain indice de projection est optimisé. Dans notre cas, l'indice de projection est lié à la distance de Bhattacharyya moyenne que présentent les classes (définies par l'opérateur) entre elles dans le sous-espace considéré [6].

Dans notre modélisation, la probabilité en un pixel conditionnellement à son voisinage est gaussienne. On peut donc calculer facilement la distance comme une fonction du voisinage (ici dans le cas d'un seul type de voisin) :

$$oldd_B(m_s) = \frac{1}{8} \|\mu_0(m_s) - \mu_1(m_s)\|_{\Sigma_{01}} + \frac{1}{2} \ln \left(\frac{|\Sigma_{01}|}{\sqrt{|\Sigma_0||\Sigma_1|}} \right) \quad (10)$$

avec $\mu_i(m_s) = a_i' m_s + b_i$ et $\Sigma_{01} = \frac{\Sigma_0 + \Sigma_1}{2}$, le terme b_i , lié à la moyenne de la texture, étant rajouté pour pouvoir traiter les textures de moyenne non nulle.

Pour chaque couple de classes, on définit un indice partiel $I_{i,j}$:

$$I_{i,j} = E\{d_B(m_s)\} = \int d_B(m_s) f(m_s) dm_s \quad (11)$$

L'indice de projection, dans le cas général à plusieurs classes est alors :

$$I = \min_{i,j} I_{i,j} \quad (12)$$

4 Résultats

Les tests de classification sont réalisés à partir d'une image AVIRIS prise en 1997 au-dessus de la région de Moffett Field, en Californie.

4.1 Collage de textures

On teste dans un premier temps l'algorithme sur le collage de 4 textures extraites de l'image de test, que l'on peut voir figure 1.

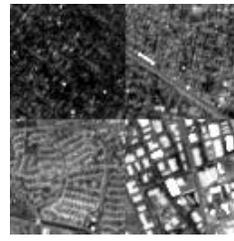


FIG. 1 – Une bande spectrale du collage de textures urbaines extraites d'une scène AVIRIS.

On compare les résultats de classification donnés par plusieurs méthodes et diverses modélisations dans le tableau 1, pour des réductions d'espace à 10 ou 20 dimensions. Pour ces exemples, il est possible d'évaluer directement les méthodes par le taux de bonne classification. L'analyse en composantes principales est notée ACP, elle est suivie d'une classification par maximum de vraisemblance gaussien pixélique. La poursuite de projection fondée sur le même modèle est notée PP-G, et le critère de classification est aussi le maximum de vraisemblance associé à ce modèle. La poursuite de projection utilisant un modèle markovien gaussien est notée PP-MG, et la classification associée repose sur un critère de maximum de vraisemblance associé au modèle markovien gaussien.

On constate que pour des textures à faible variabilité, comme dans le collage testé, les modèles pixéliques sont capables de saisir la plupart de l'information présente.

4.2 Image réelle

On effectue, dans un deuxième temps, des tests de classification sur l'image réelle AVIRIS de Moffett Field.

Dans ces tests, on compare les résultats de classification utilisant la poursuite de projection fondée sur deux modélisations différentes, la première étant la modélisation gaussienne utilisée par Jimenez et Landgrebe dans [5], et la seconde étant la modélisation proposée dans cet article.

Dans toutes les figures, les résultats montrent la classification des zones urbaines, les autres classes étant regroupées en une classe globale dite de "non-urbain". Nous avons défini deux types de tissus urbains. Le premier consiste en de grands bâtiments bien séparés, tandis que le deuxième est constitué de petits bâtiments serrés, les zones résidentielles.

La figure 2 montre le résultat de la classification fondée sur le modèle markovien gaussien présenté, considérant un type de voisinage, en 4-connexité.

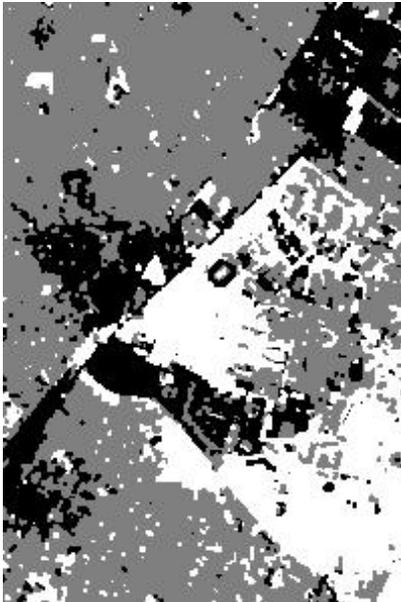
Nous avons défini quelques zones de validation sur cette image, grâce à des cartes de la région. Avec des espaces de dimension finale égale, on obtient avec le modèle non contextuel un taux de classification pour les grands bâtiments de 80.3% et pour la classe "zones résidentielles" un taux de 97.6%. Pour la méthode que nous avons présentée, on obtient des taux respectivement de 82.2% et 96.5%. On constate donc une amélioration de la classification, sur les zones plus texturées comme les grands bâtiments, avec une classification légèrement moins bonne des zones résidentielles.

TAB. 1 – Taux de bonne classification (%) du collage de textures par différents modèles et méthodes de réduction d'espace (le sous-espace extrait est de dimension 10 et 20)

Type de réduction d'espace	Taux de classification (10 bandes)	Taux de classification (20 bandes)
ACP	85.1	88.3
PP-G	86.7	88.7
PP-MG	84.5	88.0



a)



b)

FIG. 2 – a) Une bande de l'image initiale, b) résultat de classification sur 40 bandes extraites par poursuite de projection sur le modèle markovien gaussien. Noir : grands bâtiments, gris : zones résidentielles, blanc : reste.

5 Conclusion

Nous avons présenté un modèle markovien de texture utilisable pour l'analyse d'image hyperspectrale. Ce modèle permet une analyse de la texture dans ses aspects à la fois spatiaux, par les interactions entre pixels, et spectraux, par l'utilisation d'une méthode vectorielle. Ce modèle peut être inclus dans un algorithme de classification par maximum de vraisemblance. Les tests que nous avons réalisés consistent en une classification précédée d'une réduction de la dimension de l'image de manière à diminuer les problèmes d'estimation de paramètres.

Les résultats montrent que la prise en compte de la texture peut être bénéfique dans le cas d'images ou les classes texturées ne sont pas très homogènes. Dans le cas contraire, c'est-à-dire pour des images très simples comme des collages de textures très différentes, un modèle non-contextuel donne des résultats similaires.

Remerciements

Le premier auteur remercie la région Provence-Alpes-Côte d'Azur et Alcatel Space Industries pour le soutien financier apporté à sa thèse. Les auteurs remercient le JPL pour la mise à disposition de l'image AVIRIS, et le Dr. Robin Morris de Nasa Ames RC, pour les cartes fournies.

Références

- [1] Haralick (R. M.). – Statistical and structural approaches to texture. *Proc of the IEEE*, vol. 67, n 5, 1979, pp. 786–804.
- [2] Jain (A. K.) et Farrokhnia (F.). – Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, vol. 24, n12, 1991, pp. 1167–1186.
- [3] Hughes (G.F.). – On the mean accuracy of statistical pattern recognizers. *IEEE Trans. on Information Theory*, vol. 14, n1, 1968, pp. 55–63.
- [4] Besag (J.). – Spatial interaction and the statistical analysis of lattice systems. *J. Roy. Stat. Soc. B*, vol. 36, 1974, pp. 192–236.
- [5] Jimenez (L. O.) et Landgrebe (D. A.). – Hyperspectral data analysis and supervised feature reduction via projection pursuit. *IEEE Trans. on Geoscience and Remote Sensing*, vol. 37, n6, 1999, pp. 2653–2667.
- [6] Rellier (G.), Descombes (X.), Falzon (F.) et Zerubia (J.). – *La poursuite de projection pour la classification d'image hyperspectrale texturée.* – Rapport de Recherche INRIA 4152, mars 2001.