



ELSEVIER

www.elsevier.com/locate/natsci

VIE SCIENTIFIQUE

Méthodes de classification du parcellaire (synergie visible / hyperfréquences) ☆

Classification methods of agronomic cultures (microwave and visible / infrared electromagnetic wave lengths)

Sylvie Le Hégarat-Masclé *

Physicienne, CETP/CNRS, 10-12 avenue de l'Europe, 78140 Vélizy, France

L'observation de différents types d'occupation de la surface constitue, si ce n'est la première, pour le moins une des premières applications de la télédétection. Dans le cas de zones agricoles, il s'agit d'identifier les différentes cultures du parcellaire. En découlent des applications telles que : la mise à jour de cartes de cultures pour le recensement agricole, la sélection de cibles pour l'estimation de paramètres géophysiques caractérisant la surface (tels que le contenu en eau du sol, cf. contribution « mesures d'humidité des sols (et végétation) par radar aéroporté », Quesney et al., 2000) ou encore la modélisation des échanges Sol-Végétation-Atmosphère (e.g. Bernard et al., 1986), par exemple pour des applications météorologiques ou climatiques.

Pour l'identification du parcellaire, le capteur utilisé doit nécessairement être haute résolution (pixel de taille inférieure à celle des champs). Classiquement, on distingue les capteurs optiques qui acquièrent des données dans le visible jusqu'à l'infrarouge (tels que SPOT/HRV ou LANDSAT/TM) et qui présentent l'avantage d'être efficaces pour la distinction de nombreux types de végétation et les capteurs hyperfréquences SAR (*Synthetic Aper-*

ture Radar ou RSO, Radar à Synthèse d'Ouverture, selon la terminologie française, tels que les SAR des satellites ERS, RadarSAT, EnviSAT), qui présentent l'avantage d'être indépendants des conditions d'illumination de la cible et fournissent une information complémentaire de celle acquise dans le domaine visible/infrarouge. Dans le cas de capteurs optiques, le vecteur caractéristique (utilisé dans la suite pour la classification) est constitué des valeurs radiométriques des différents canaux spectraux. Dans le cas de capteurs hyperfréquences, le vecteur caractéristique est soit déduit de la matrice de rétrodiffusion complexe (Rignot et al., 1992) si le capteur est polarimétrique (AIRSAR, SIR-C), soit constitué des coefficients de rétrodiffusion acquis aux différentes dates si l'on considère des données multitemporelles (ERS/SAR). Évidemment, on peut également utiliser les deux types de capteurs en synergie.

Les principales étapes préalables à la classification sont les suivantes : (1) choix d'un modèle d'image, (2) choix d'une méthode d'estimation des caractéristiques des classes : supervisée (avec apprentissage ou par modélisation) ou non supervisée, (3) choix d'une méthode de classification : aveugle, contextuelle ou globale et (4) définition d'un critère de performance afin d'évaluer la qualité des résultats de classification : nombre de pixels mal classés, taux d'identification des différents types d'occupation du sol. Dans la suite, nous présenterons succinctement ces différents points, avant

☆ Compte rendu du séminaire (PEVS, Zone atelier) : « Mesures aéroportées pour l'observation du sol et des paysages : la mesure *in situ* et la télédétection ».

* Auteur correspondant.

Adresse e-mail : Sylvie.MASCLE@cetp.ipsl.fr
(S. Le Hégarat-Masclé).

d'introduire le principe de la fusion de données et d'en annoncer les très fortes potentialités et enfin de conclure.

Mise en œuvre d'une méthode de classification monosource

Modélisation de l'image

Le paragraphe qui suit utilise un formalisme statistique pour déterminer les propriétés des informations contenues dans l'image et effectuer une classification de ces informations. Cette approche de classification par différentes méthodes doit permettre une approche plus ou moins « non supervisée », c'est-à-dire automatique, du traitement d'image : par exemple, sur des observations de télédétection aéroportée ou spatiale, il s'agit de l'analyse automatique de parcelles agricoles atteints par une maladie, analyse de types de peuplements agricoles etc.

Soit X l'image des données (ou observable) : $X = \{x_s, s \in S\}$ et Λ l'image des labels : $\Lambda = \{l_s, s \in S\}$ ou classes. Le problème de la classification consiste alors à estimer Λ connaissant X . Selon la théorie bayésienne, le critère d'optimalité est la minimisation du coût moyen. Celui-ci fait intervenir les probabilités a posteriori $p(\Lambda/X)$ ou la loi conditionnelle de X connaissant Λ et la loi *a priori* de Λ . Dans la suite, on choisit pour la loi conditionnelle une distribution gaussienne (vérifiée dans la plupart des cas de par le théorème de la limite centrée) et pour la loi *a priori*, une modélisation en champs de Markov (Besag, 1974), avec par exemple un modèle de Potts 8-connexité (Potts, 1952).

Détermination des caractéristiques des classes

Pour la détermination des caractéristiques des classes, on distingue l'approche supervisée et celle non supervisée. Dans la première, les classes sont connues *a priori* et leurs caractéristiques sont issues soit de la modélisation, soit de l'apprentissage sur des zones test de position connue sur l'image. Dans le cas non supervisé, les classes sont inconnues *a priori* et sont déterminées d'après un critère mathématique de type minimisation d'une erreur quadratique ou d'une fonction de coût.

Approche supervisée

La première approche supervisée possible est la modélisation physique directe du signal mesuré par le capteur à partir des propriétés géophysiques (connues *a priori*) des classes recherchées. Par

exemple, on peut citer la classification pour les données polarimétriques en trois grands mécanismes de rétrodiffusion : nombre de réflexions impair, nombre de réflexions pair et rétrodiffusion diffuse (van Zyl, 1989 ; Macle et al., 1994) ; ou la classification, pour les régions semi-arides, en quatre grandes classes de densités de végétation (Zribi et al., 2001).

Les deux principaux avantages de cette approche physique sont l'interprétation immédiate des résultats et le caractère automatique des algorithmes ; l'inconvénient majeur est la nécessité d'une connaissance *a priori* importante (milieu physique, modélisation des interactions onde-surface...).

La seconde approche supervisée est aussi la plus répandue. Elle consiste à réaliser l'apprentissage des caractéristiques des classes sur des zones test sélectionnées par un opérateur. Elle ne peut donc pas être automatisée et nécessite également une information *a priori* importante (vérité terrain sur les zones test). Cependant, comme la précédente elle offre l'avantage d'une interprétation immédiate des résultats : correspondance entre les classes et les types d'occupation du sol pré-établie au moment de l'apprentissage.

Approche non supervisée

Ce type d'approche est intéressant soit lorsque l'on ne dispose que de peu d'information *a priori* sur les classes recherchées, soit lorsque l'on souhaite rester « proche » de l'information effective de l'image. En effet, dans le cas non supervisée, les classes trouvées correspondent à des distinctions réelles entre les signaux acquis : ainsi, par exemple, si deux types d'occupation du sol ne sont pas discernables du point de vue de leur interaction avec l'onde du capteur considéré, ils appartiendront à la même classe ; et inversement, si un même type d'occupation du sol présente différents états (humidité, croissance de la végétation,...), il pourra lui correspondre plusieurs classes. Le résultat de cette approche non supervisée est donc indépendant de l'application (il est fondé uniquement sur l'information présente dans l'image). La contrepartie est alors une interprétation plus complexe et plus délicate des classes ainsi mathématiquement déterminées.

Parmi les algorithmes les plus robustes d'estimation des caractéristiques des classes, on peut citer le Fuzzy C-Means (Bezdek et al., 1984), qui permet de prendre en compte le caractère mixte de certains pixels.

Classifications bayésiennes

Les méthodes de classifications bayésiennes diffèrent par les sous-ensembles X' de X et Λ' de Λ , avec

Λ' estimé à partir de X' . Ainsi, si Λ' et X' sont réduits à un pixel, on parlera de classification ponctuelle (aucune information de voisinage spatial des pixels n'est exploitée). Si X' est réduit au voisinage du pixel ou groupe de pixels dont on cherche le label, on parlera de classification contextuelle et si X' est l'image entière ($X' = X$), on parlera de classification globale.

Ces dernières méthodes sont bien sûr les plus performantes puisqu'elles utilisent l'ensemble de l'information présente sur l'image : information radiométrique mais aussi information de voisinage spatial des différents pixels, mais ce sont également les plus complexes à mettre en œuvre. Parmi celles-ci, la classification MPM (*Maximum of the Posterior Marginale*) permet de minimiser en théorie le nombre de pixels mal classés, mais est assez lourde à implémenter (simulation d'une chaîne de Markov admettant pour limite la distribution $p(\Lambda/X)$ (Chalmond, 1989), alors que la classification MAP (*Maximum A Posteriori*) peut être atteinte plus facilement par recuit simulé (Geman et Geman, 1984 ; Le Hégarat-Masclé et al., 1996) et est donc couramment utilisée.

Critère de performance

Le critère retenu est celui du taux d'identification de chaque type d'occupation du sol (Le Hégarat-Masclé et al., 1997). Celui-ci représente le degré de confiance que l'on peut avoir en interprétant les classes représentant ce type d'occupation du sol. Ainsi, si un type d'occupation du sol n'est représenté que par des classes non mixtes (ne représentant que ce type d'occupation), son taux d'identification sera de 100 %. En revanche, pour les types d'occupation du sol représentés par des classes mixtes, les taux d'identification seront inférieurs à 100 %. En général, on considère qu'un taux d'identification inférieur à 80 % est insuffisant.

Ce critère est préféré à celui du nombre de pixels mal classés, car il renseigne sur les différentes performances de la classification pour chacun des différents types d'occupation du sol. Par ailleurs, il est plus synthétique que les matrices de confusion, à partir desquelles il est calculé, mais qui sont parfois difficilement lisibles dans le cas de classes non supervisées (en nombre variable).

Fusion de données

La fusion de données consiste à combiner des informations acquises par différents capteurs (« multi-sources ») afin de (1) réduire les erreurs de classification en exploitant la redondance entre les

informations acquises par les différents capteurs et (2) mettre en évidence des classes indiscernables au vu de l'information acquise en monosource, en exploitant la complémentarité des informations multisources. Dans la suite on considère que pour chacune des images acquises, on dispose de l'image des données brutes, d'un fichier des caractéristiques des classes (monosources) et d'une image des labels (résultat de la classification monosource).

Les principales approches possibles sont alors : la théorie bayésienne (des probabilités), la théorie des possibilités et celle des croyances. Cette dernière est, comme nous allons le voir, particulièrement bien adaptée, à notre problème, c'est donc celle sur laquelle nous nous appuyerons.

Théorie des croyances

La théorie des croyances introduite d'abord par Dempster dans les années 1960, puis étendue par Shafer (Shafer, 1976) permet la prise en considération d'hypothèses composées (et non seulement celle d'hypothèses simples ou singletons), telles que « est-ce que le pixel appartient à l'union des deux classes C_1 et C_2 (plutôt qu'à C_1 ou C_2) ? ». Pour notre propos, elle est donc très attractive car elle permet de modéliser très simplement le caractère indiscernable de certaines classes au vu de l'information acquise par un seul capteur : il suffit alors d'affecter une masse (équivalent des probabilités de la théorie bayésienne) non nulle à l'union de ces classes. On peut également modéliser une ignorance globale (cas de données manquantes en particulier) en affectant une masse non nulle à l'union de toutes les classes.

Outre les fonctions de masse, cette théorie utilise deux autres fonctions : la plausibilité et la croyance, à partir de la différence desquelles on peut quantifier l'imprécision sur l'incertitude d'une hypothèse (alors que la théorie bayésienne suppose exactes ou parfaitement précises, les valeurs de probabilités des différentes hypothèses manipulées). Enfin, une estimation du conflit entre les informations acquises par les différents capteurs est possible à partir de la masse de l'ensemble vide.

Un algorithme non supervisé estimant directement les classes discernables par la fusion à partir des résultats des classifications monosources a été développé (Le Hégarat-Masclé et al., 1997), qui a prouvé son efficacité sur différents jeux de données (Le Hégarat-Masclé et al., 1997 ; Le Hégarat-Masclé et al., 2000).

Cette théorie a aussi été utilisée pour la détermination de l'occupation du sol par fusion de données optiques avec couverture nuageuse partielle

(cas typique de données manquantes) avec des données ERS/SAR monodate (cas typique de données imprécises) et a encore une fois fait la preuve de son efficacité (Le Hégarat-Mascle et al., 1998). En particulier, on a montré qu'avec cette théorie, le poids de l'information de voisinage spatial dans la décision finale pouvait être automatiquement ajusté au degré d'ignorance radiométrique : plus cette l'information radiométrique est imprécise, plus on a va accorder de crédit à l'information spatiale.

Conclusion

Le potentiel de la télédétection haute résolution pour l'identification des différents types d'occupation du sol n'est plus à démontrer aujourd'hui. Les résultats les plus performants sont obtenus par fusion de données acquises par différents capteurs, ce qui permet d'une part de réduire les erreurs de classification dues au bruit de chacun des capteurs pris individuellement et d'autre part, d'identifier de nouveaux types d'occupation du sol précédemment indiscernables, grâce à la complémentarité des informations.

Références

- Bernard, R., Soarès, J.V., Vidal-Madjar, D., 1986. Differential bare field drainage properties from airborne microwave observation. *Water Resources Research* 22 (6), 869-875.
- Besag, J., 1974. Spatial interaction and the statistical analysis of lattice systems. *Journal of the Royal Statistical Society. Series B* 36, 192-236.
- Bezdek, J.C., Ehrlich, R., Full, W., 1984. FCM: the fuzzy c-means clustering algorithm. *Computers and Geoscience* 10 (2-3), 191-203.
- Chalmond, B., 1989. An iterative Gibbsian technique for reconstruction of m-ary images. *Pattern Recognition* 22 (6), 747-761.
- Geman, S., Geman, D., 1984. Stochastic relaxation, Gibbs distribution and Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 6 (6), 721-741.
- Le Hégarat-Mascle, S., Vidal-Madjar, D., Olivier, P., 1996. Applications of simulated annealing to SAR image clustering and classification problems. *International Journal of Remote Sensing* 17 (9), 1761-1776.
- Le Hégarat-Mascle, S., Bloch, I., Vidal-Madjar, D., 1997. Application of Dempster-Shafer evidence theory to unsupervised classification in multisource remote sensing. *IEEE Transactions on Geoscience and Remote Sensing* 35, 1018-1031.
- Le Hégarat-Mascle, S., Bloch, I., Vidal-Madjar, D., 1998. Introduction of neighborhood information in evidence theory and application to data fusion between radar and optical images with partial cloud cover. *Pattern Recognition* 31 (11), 1811-1823.
- Le Hégarat-Mascle, S., Quesney, A., Vidal-Madjar, D., Taconet, O., Normand, M., Loumagne, C., 2000. Land cover discrimination from multitemporal ERS images and multispectral LANDSAT images: a study case in an agricultural area in France. *International Journal of Remote Sensing* 21 (3), 435-456.
- Mascle, S., Olivier, P., Vidal-Madjar, D., 1994. Identification of vegetation classes using multi-configuration polarimetric SAR data. *Proceedings Progress In Electromagnetism Research Symposium*.
- Potts, R.B., 1952. Some generalized order-disorder transformations. *Proceedings of the Cambridge Philosophical Society* 48, 106-109.
- Quesney, A., Le Hégarat-Mascle, S., Taconet, O., Vidal-Madjar, D., Wigneron, J.P., Loumagne, C., Normand, M., 2000. Estimation of watershed soil moisture index from ERS/SAR data. *Remote Sensing of Environment* 72 (3), 290-303.
- Rignot, E., Chellappa, R., Dubois, P., 1992. Unsupervised segmentation of polarimetric SAR data using the covariance matrix. *IEEE Transactions on Geoscience and Remote Sensing* 30 (4), 697-704.
- Shafer, G., 1976. *A Mathematical Theory of Evidence*. Princeton, NJ: Princeton University Press.
- Van Zyl, J.J., 1989. Unsupervised classification of scattering behavior using radar polarimetric data. *IEEE Transactions on Geoscience and Remote Sensing* 27 (1), 36-45.
- Zribi, M., Le Hégarat-Mascle, S., Taconet, O., Ciarletti, V., Vidal-Madjar, D., Boussema, M., 2001. Derivation of wild vegetation cover density in a semi-arid regions: ERS2 radar evaluation. *International Journal of Remote Sensing*, in press.

Available online at www.sciencedirect.com

SCIENCE @ DIRECT®