

# MISE EN PLACE D'UNE METHODE SEMI-AUTOMATIQUE DE CARTOGRAPHIE DE L'OCCUPATION DES SOLS A PARTIR D'IMAGES RSO POLARIMETRIQUES

Monique Moine<sup>1</sup>, Henri Giraud<sup>1</sup>, Anne Puissant<sup>2</sup>

1 : ICUBE-Service Régional de Traitement d'Images et de Télédétection (SERTIT), UMR CNRS 7357, Université de Strasbourg  
monique.wolff@etu.unistra.fr, henri.giraud@unistra.fr

2 : Laboratoire Image, Ville, Environnement (LIVE), UMR CNRS 7362, Université de Strasbourg  
anne.puissant@live-cnrs.unistra.fr

## Résumé

Les cartes d'occupation du sol produites à des résolutions spatiales et temporelles élevées constituent actuellement une ressource très importante pour beaucoup d'organismes privés ou publics. Le développement de méthodes de cartographie automatique, fiables et robustes basées sur la classification d'images satellites constitue ainsi un enjeu majeur. Dans ce cadre, l'imagerie radar apporte l'avantage de fournir des images de jour comme de nuit, et quelles que soient les conditions météorologiques. Plus récemment, l'exploitation des informations de rétrodiffusion fournies par les images RSO (Radar à Synthèse d'Ouverture) polarimétriques a permis d'étendre les possibilités apportées par l'imagerie radar. Dans cette étude, une carte d'occupation du sol a été produite sur une partie de la plaine d'Alsace et du massif vosgien à partir (1) de 76 paramètres polarimétriques extraits d'une image ALOS PALSAR en polarisation quadruple et (2) d'une méthode de classification orientée-objet. Plusieurs algorithmes de classification supervisée ont été testés et l'algorithme du plus proche voisin est ressorti comme donnant les meilleurs résultats. La méthode mise en place a l'avantage d'être semi-automatique et facilement reproductible. Neuf classes d'occupation du sol ont été cartographiées avec un taux de bon classement de 69%. Plus précisément, trois d'entre elles ont été très correctement détectées : la forêt, l'urbain et l'eau. D'autres classes ont été confondues du fait de la similarité de leur signature polarimétrique : les zones de vignobles, les prairies et les zones de cultures. Enfin, trois classes non visibles sur les données *a priori* et les images optiques de référence ont pu être identifiées sur l'image polarisée. Ces premiers résultats sont prometteurs pour la cartographie de l'occupation des sols à partir d'images RSO polarimétriques.

**Mots-clés :** SAR, polarimétrie, cartographie, occupation du sol, classification orientée-objet

## Abstract

*Today, land cover maps with good spatial and temporal resolution represent an essential resource for many private and public bodies from local to international levels. Hence, given the task at hand the development of automatic, reliable and robust techniques of cartography is a major issue. Within this framework, radar imagery has the advantage of supplying day and night images, regardless of the weather conditions. Recently, the use of the backscattering information provided by SAR (Synthetic Aperture Radar) polarimetric images has extended the possibilities given by radar imagery. In this study, a land cover map was produced over a part of the Alsace region using (1) 76 polarimetric parameters extracted from a quad-polarised ALOS PALSAR image and (2) an object-oriented classification method. Several algorithms have been tested and the nearest neighbor algorithm appeared to give the best results. The method has the advantage to be semi-automatic and replicable. Nine land cover classes have been mapped with a 69% classification success rate. Of these, three classes were better identified: forest, urban areas and water. Other classes were mixed due to their similar polarimetric signatures: vineyards, grasslands and cultivated fields. Finally, three classes were observed on the polarimetric image, that couldn't be observed in a priori data and reference optical images. These first results are promising for land cover mapping based on polarimetric SAR images.*

**Keywords:** SAR, polarimetry, cartography, land cover, object-oriented classification

## 1. Introduction

L'imagerie radar apparaît aujourd'hui comme un complément essentiel à l'imagerie optique en tant que support à la mise à jour régulière de cartes d'occupation des sols. Elle a l'avantage de fournir des données de jour comme de nuit et indépendamment des conditions météorologiques. Depuis une vingtaine d'années, l'exploitation de l'information supplémentaire fournie par les caractéristiques de polarimétrie des images radar (i.e. la propriété qu'ont les vecteurs des champs électrique et magnétique du signal électromagnétique à prendre différentes directions au cours de leur propagation) s'est fortement développée. Le nombre de satellites équipés de capteurs permettant

l'acquisition d'images RSO (Radar à Synthèse d'Ouverture) en polarisation multiple (i.e. provenant d'un capteur capable d'émettre et de recevoir un signal électromagnétique dans les différentes combinaisons de polarisation, comprenant généralement une composante horizontale H et une composante verticale V pour une base de polarisation linéaire) a connu une forte progression. Citons par exemple les satellites Radarsat-2, TerraSAR-X, Cosmo-SkyMed, ALOS et ALOS-2 (images en polarisation quadruple), ou Sentinel-1 (images en polarisation double). Par ailleurs, des travaux de recherches ont mis en évidence des paramètres permettant de caractériser le signal radar polarisé et ainsi d'établir des signatures polarimétriques caractéristiques des objets au sol. Différentes méthodes de décomposition du signal radar polarisé



plaine présente au Sud-Est de l'image est occupée par des zones cultivées, principalement des cultures de maïs, quelques prairies, quelques forêts de feuillus et de petites zones urbaines. Enfin, la zone montagneuse et la plaine sont séparées par une zone de piémont principalement occupée par des vignobles.

La Base de Données d'Occupation du Sol de la Coopération pour l'Information Géographique en Alsace (BD OCS CIGAL, 2008) a été utilisée comme donnée de référence pour la définition des classes et la validation de la méthode. Une image multispectrale SPOT 5 à 2,5 m de résolution acquise le 25 avril 2007 (i.e. trois jours après l'acquisition de l'image ALOS) a également servi de support à la validation.

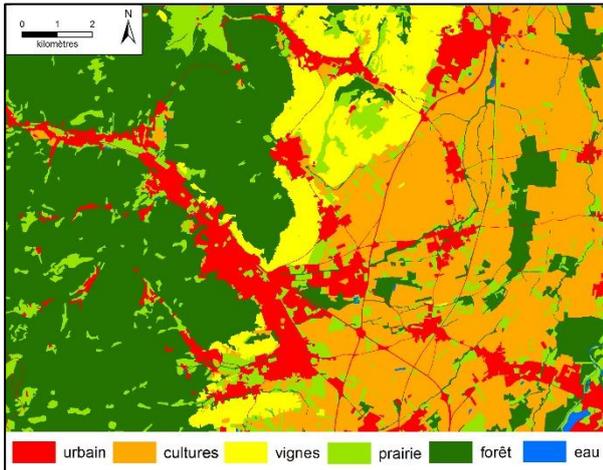


Figure 2 : Occupation du sol sur la zone test (source : BD OCS CIGAL, 2008).

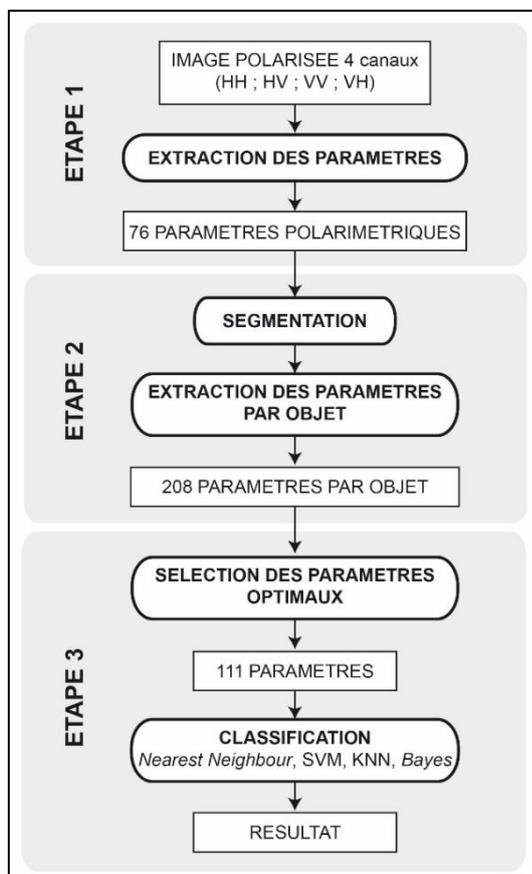


Figure 3 : Etapes de la démarche méthodologique.

### 3. Méthodologie

Une démarche méthodologique en trois étapes a été suivie dans cette étude (Figure 3) :

- (1) extraction de paramètres polarimétriques à partir des quatre canaux de l'image ALOS PALSAR ;
- (2) analyse orientée-objet (segmentation, extraction de paramètres et sélection d'échantillons d'entraînement) ;
- (3) sélection des paramètres optimaux et classification avec test de quatre algorithmes différents (i.e. *Nearest Neighbour*, SVM, KNN et *Bayes*).

L'extraction des paramètres polarimétriques a été réalisée grâce au logiciel PolSARpro, développé par l'ESA pour permettre le traitement des images polarimétriques (Pottier et Ferro-Famil, 2012). Les étapes d'analyse orientée-objet et de classification ont été réalisées sous eCognition Developer 8.8 (Trimble, 2013).

#### 3.1. Extraction des paramètres polarimétriques

Les théorèmes de décomposition polarimétrique permettent de faciliter l'interprétation des images polarimétriques en décomposant le signal radar polarisé en une combinaison des principaux mécanismes de rétrodiffusion (i.e. rétrodiffusion de volume, rétrodiffusion de double-rebond, rétrodiffusion de surface). La plupart des décompositions polarimétriques s'appuient sur la matrice de cohérence, qui est extraite à partir des quatre canaux de l'image polarisée. Dans le cas fréquent d'une configuration monostatique (i.e. où l'émission et la réception du signal se font depuis le même capteur), le théorème de réciprocité implique que les canaux HV et VH sont égaux (Lee et Pottier, 2009) et la matrice de cohérence s'écrit de la manière suivante :

$$[T_3] = \frac{1}{2} \begin{bmatrix} |S_{HH} + S_{VV}|^2 & (S_{HH} + S_{VV})(S_{HH} - S_{VV})^* & 2(S_{HH} + S_{VV})S_{HV}^* \\ (S_{HH} - S_{VV})(S_{HH} + S_{VV})^* & |S_{HH} - S_{VV}|^2 & 2(S_{HH} - S_{VV})S_{HV}^* \\ 2S_{HV}(S_{HH} + S_{VV})^* & 2S_{HV}(S_{HH} - S_{VV})^* & 4|S_{HV}|^2 \end{bmatrix}$$

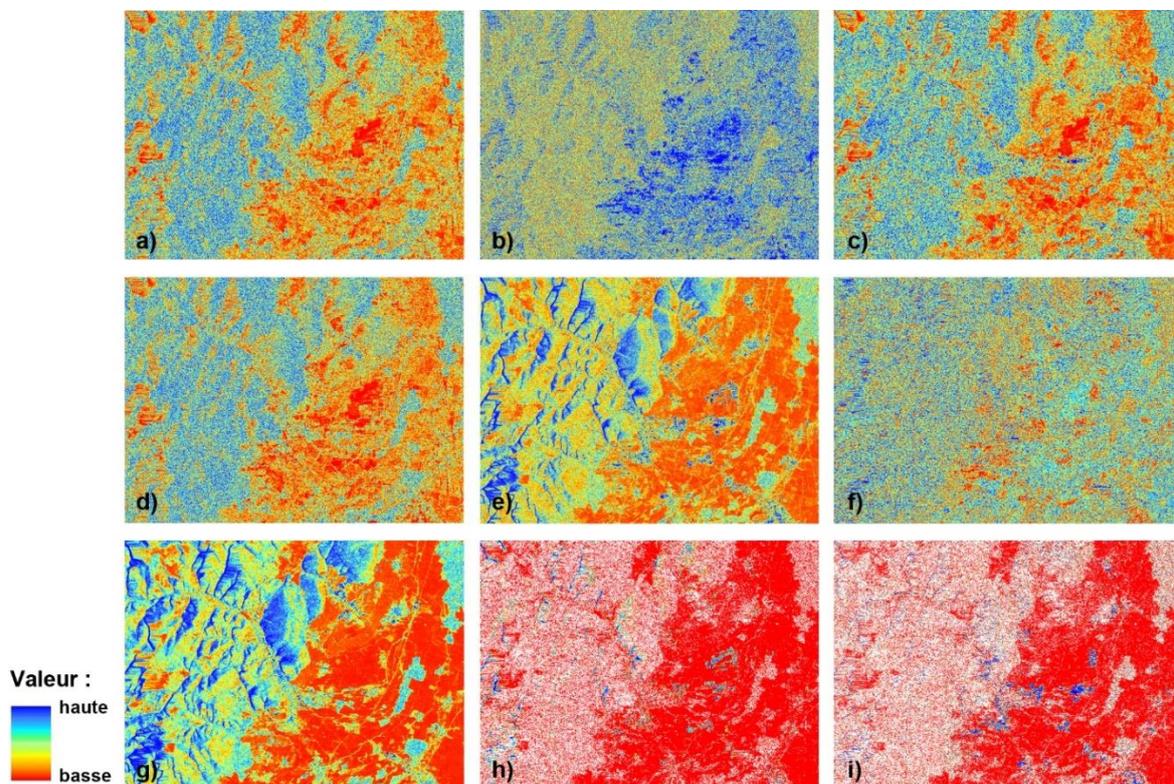
Dans cette étude, 76 paramètres issus de neuf décompositions polarimétriques ont été extraits à partir de l'image ALOS PALSAR. Ces paramètres sont présentés dans le Tableau 1 et quelques exemples des images représentant ces paramètres sont présentés dans la Figure 4.

Trois des paramètres extraits forment la composition colorée dite 'Pauli RGB'. Elle est créée à partir de la décomposition de Pauli et concentre la majorité de l'information polarimétrique (Figure 5). Les trois bandes de l'image sont composées à partir des canaux de l'image polarisée (rouge = HH-VV, vert = 2HV et bleu = HH+VV, dans le cas d'une configuration monostatique). Cette représentation est la plus utilisée pour l'interprétation visuelle des images polarimétriques car elle permet d'identifier clairement les trois principaux mécanismes de rétrodiffusion : la rétrodiffusion de double-rebond (en rouge), la rétrodiffusion de volume (en vert) et la rétrodiffusion de surface (en bleu).

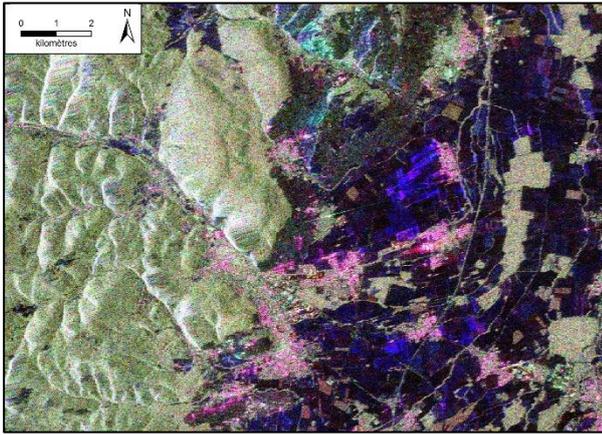
Les 76 paramètres ont ensuite été combinés dans une image multi-bandes (chaque bande correspondant à un paramètre) pour servir d'entrée à l'analyse orientée-objet.

Méthode de décomposition	Paramètres
	amplitude_HH ; amplitude_VV ; amplitude_HV ; amplitude_VH
Pauli	Pauli_1 (bande rouge) ; Pauli_2 (bande verte) ; Pauli_3 (bande bleue) ; ratio_HH_HV ; ratio_HH_VH ; ratio_HH_VV ; ratio_VV_HV ; ratio_VV_VH ; ratio_VV_HH ; span
Krogager (Krogager, 1990)	Krogager_Ks ; Krogager_Kd ; Krogager_Kh
Van Zyl (1989)	VanZyl_vol ; VanZyl_odd ; VanZyl_dbl
Freeman-Durden (Freeman et Durden, 1998)	Freeman_vol ; Freeman_odd ; Freeman_dbl
Yamaguchi (Yamaguchi et al., 2005)	Yamaguchi_vol ; Yamaguchi_odd ; Yamaguchi_dbl ; Yamaguchi_hlx
An-Yang (An et al., 2011)	An-Yang_vol ; An-Yang_odd ; An-Yang_dbl ; An-Yang_hlx
H/A/alpha (Cloude et Pottier, 1997)	entropy ; anisotropy ; alpha ; vecteurs propres (alpha ( $\alpha_1, \alpha_2, \alpha_3$ ) ; beta ( $\beta_1, \beta_2, \beta_3$ ) ; gamma ( $\gamma_1, \gamma_2, \gamma_3$ ) ; delta ( $\delta_1, \delta_2, \delta_3$ )) ; valeurs propres (l1, l2, l3) ; pseudo-probabilités (p1, p2, p3) ; shannon_entropy (shannon_entropy, shannon_entropy_norm, shannon_entropy_l, shannon_entropy_l_norm, shannon_entropy_P, shannon_entropy_P_norm) ; anisotropy_lueneburg ; anisotropy_kozlov (anisotropy_kozlov, anisotropy_complex_kozlov, anisotropy_complex_kozlov_norm) ; anisotropy_12 DERD ; DERD_norm ; SERD ; SERD_norm ; RVI ; polarisation_fraction ; pedestal height ; asymmetry
Touzi (Touzi, 2007)	TSVM_alpha ; TSVM_tau ; TSVM_phi ; TSVM_psi
Praks & Colins (Praks et al., 2009 ; Colin-Koeniguer et al., 2010)	scattering_predominance ; scattering_diversity ; degree_purity ; depolarization_index

**Tableau 1** : Paramètres polarimétriques testés dans cette étude. Les quatre paramètres d'amplitude sont réels et correspondent aux images d'intensité des quatre canaux de l'image ALOS. Les autres paramètres sont complexes et sont issus de neuf décompositions polarimétriques différentes.



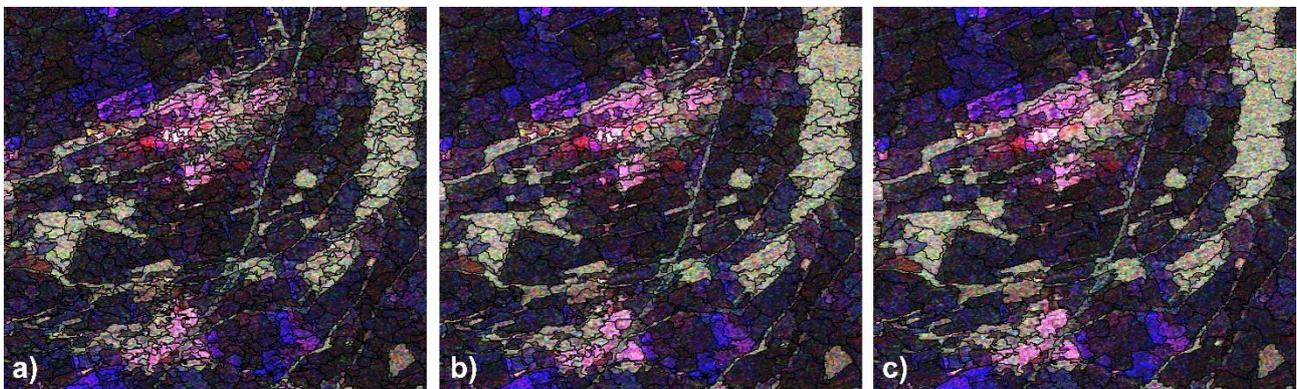
**Figure 4** : Exemples de paramètres polarimétriques utilisés pour l'étude (avec zoom sur la zone test) : a) *entropy*, b) *anisotropy*, c) *alpha angle*, d) *Radar Vegetation Index*, e) *SPAN*, f) *ratio HH/VH*, g) *Freeman volume*, h) *Freeman surface*, i) *Freeman double-rebound*.



**Figure 5** : Composition colorée RGB issue de la décomposition de Pauli sur la zone test (R = HH-VV ; G = 2HV ; B = HH+VV).

### 3.2. Segmentation et calcul des paramètres par objet

La segmentation est une étape très importante car la création d'objets représentatifs de l'occupation du sol va directement conditionner les résultats finaux de la classification. Un objet parfaitement représentatif ne doit comprendre qu'une seule classe d'occupation du sol (Niu et Ban, 2013). Ici, la segmentation a été appliquée uniquement sur les trois bandes de l'image 'Pauli RGB' car celles-ci présentent une représentation condensée de l'information polarimétrique et permettaient de générer les objets les plus représentatifs. Nous avons choisi d'utiliser l'algorithme de segmentation multi-résolution qui fonctionne par croissance ascendante de régions. Le paramètre d'échelle est utilisé sous eCognition Developer pour déterminer l'hétérogénéité maximale autorisée pour les objets résultants de la segmentation (la taille des objets générés sera d'autant plus grande que le paramètre d'échelle est élevé). Différents paramètres d'échelle ont été testés et une valeur de 25 a été retenue car elle engendrait les objets les plus homogènes (Figure 6). Le paramètre de forme permet de choisir le poids donné à la forme par rapport à la couleur lors de la segmentation. Le paramètre de compacité permet de choisir d'obtenir des objets soit plutôt compacts, soit plutôt allongés. Une valeur de 0,5 a été choisie à la fois pour les paramètres de forme et de compacité, pour donner autant de poids à la forme qu'à la couleur et pour obtenir des objets de forme ni trop compacte ni trop allongée.



**Figure 6** : Comparaison de trois échelles de segmentation testées : a) *scale* = 15, b) *scale* = 20, c) *scale* = 25.

Par la suite, pour chaque objet issu de la segmentation, 208 paramètres ont été extraits à partir des paramètres calculables sous le logiciel eCognition Developer :

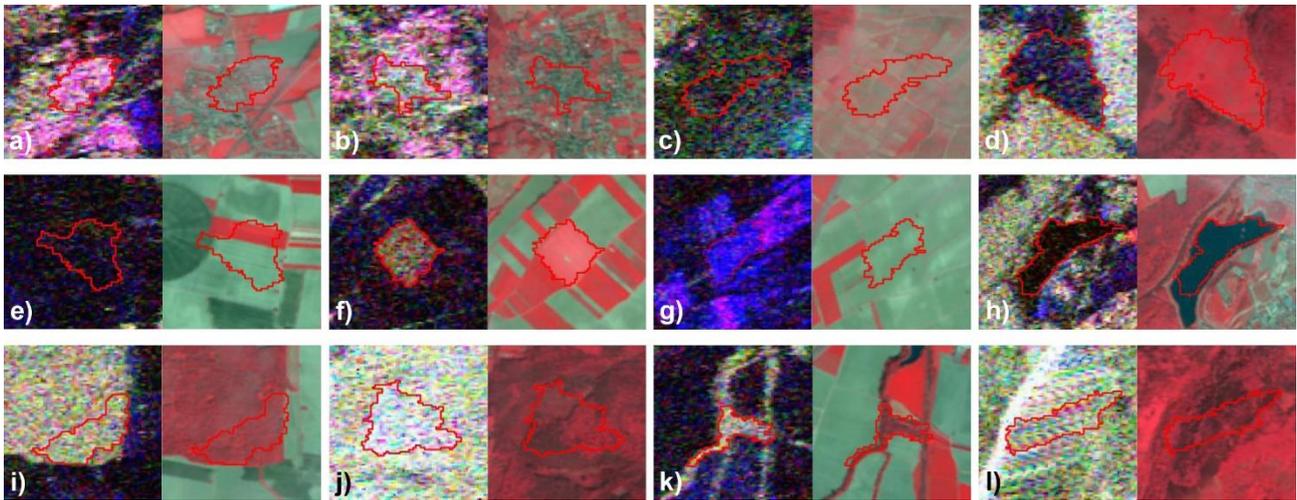
- 1) 154 paramètres correspondant à la moyenne (*mean*) et à l'écart-type (*StdDev*) calculés pour chacun des 76 paramètres polarimétriques, et aux deux paramètres *brightness* et *max. diff.* proposés par eCognition ;
- 2) 30 autres paramètres statistiques proposés par eCognition : *skewness*, *ratio*, *min. pixel value*, *max. pixel value*, *circular mean*, *circular StdDev*, *circular StdDev/mean*, *hue*, *saturation* et *intensity*, calculés pour les trois bandes du 'Pauli RGB' ;
- 3) 24 paramètres de textures : *homogeneity*, *dissimilarity*, *entropy*, *contrast*, *angle 2nd moment*, *mean StdDev* et *correlation*, calculés pour les trois bandes du 'Pauli RGB'.

Les paramètres de forme proposés par eCognition Developer n'ont pas été retenus car ils ne s'avéraient pas utiles pour la classification générale de l'occupation du sol. En effet, dans notre cas les objets d'une même classe ne sont pas caractérisés par une même géométrie ou une même position.

### 3.3. Mise en place de la typologie et échantillonnage

Pour la classification de l'image, une typologie de l'occupation du sol en douze classes a été mise en place à partir de la BD OCS CIGAL et de l'observation de l'image 'Pauli RGB' (Figure 7). La typologie comprend six classes directement issues de la BD OCS CIGAL ('urbain (1)', 'cultures (1)', 'vignes', 'prairie', 'forêt (1)' et 'eau') et six classes identifiées visuellement sur le 'Pauli RGB' ('urbain (2)', 'cultures (2)' et 'cultures (3)', 'forêt (2)', 'forêt (3)' et 'forêt (4)').

La classe 'urbain (2)' correspond aux zones où la signature de l'urbain dans le 'Pauli RGB' (rouge clair et vert, correspondant à un mélange entre rétrodiffusion de double-rebond et rétrodiffusion de volume) se rapproche fortement de celle de la forêt. Elle a été créée pour minimiser les erreurs dues à cette ressemblance et a été fusionnée avec la classe 'urbain (1)' dans le résultat final. La différence de signature polarimétrique entre ces deux classes n'est pas visible sur l'image SPOT 5 et n'a pas pu être interprétée pour le moment. Elle pourrait être liée à une différence de rugosité.



**Figure 7** : Signatures des 12 classes d'occupation du sol dans le 'Pauli RGB' (à gauche) et l'image SPOT 5 (à droite) : a) urbain (1), b) urbain (2), c) vignes, d) prairie, e) cultures (1), f) cultures (2), g) cultures (3), h) eau, i) forêt (1), j) forêt (2), k) forêt (3), l) forêt (4).

Les classes 'cultures (2)' et 'cultures (3)' sont uniquement visualisables sur le Pauli RGB (i.e. non référencées dans la BD OCS CIGAL et non identifiables sur l'image SPOT 5). La classe 'cultures (2)' correspond aux zones cultivées ayant une signature proche de celle de la forêt dans le 'Pauli RGB', dénotant une rétrodiffusion de volume. Ce sont des zones apparaissant comme ayant une activité chlorophyllienne moyenne dans l'image SPOT 5. Ce pourrait être des zones de végétation à un stade de développement moins avancé que la classe 'culture (1)' et ayant une structure différente (différence de rugosité), favorisant la rétrodiffusion de volume. La classe 'cultures (3)' correspond à des zones cultivées apparaissant en bleu dans le 'Pauli RGB' et suggérant une rétrodiffusion de surface. Elles sont très peu visibles sur l'image SPOT 5, mais des traces de ruissellement plus claires sont distinguables dans les cultures à ces endroits-là. On peut supposer qu'elles sont les traces d'une érosion du sol (un évènement de coulées boueuses a touché un village à proximité de ces zones quelque jours avant l'acquisition de l'image ALOS) ou d'une forte humidité du sol.

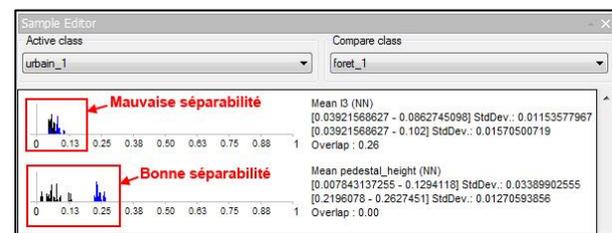
Les classes 'forêt (2)' et 'forêt (4)' correspondent à des zones forestières des versants ouest du massif vosgien affectées par l'effet de relief de l'image radar. Ces zones apparaissent très claires dans le 'Pauli RGB'. La classe 'forêt (3)' a été créée pour classer en tant que 'forêt' certaines zones de forêt qui étaient assimilées à de la prairie. Comme la classe 'urbain (2)', les trois classes additionnelles de forêt ont été créées pour minimiser les erreurs de classification et ont été fusionnées dans le résultat final.

Les algorithmes de classification testés fonctionnant tous par apprentissage, des échantillons d'entraînement ont dû être sélectionnés. Une dizaine d'objets représentatifs ont ainsi été sélectionnés pour chaque classe d'occupation du sol. L'échantillonnage a été optimisé grâce à l'outil *2D Feature Space Plot* d'eCognition. Celui-ci permet de visualiser la position des échantillons dans un nuage de points, chacune des deux dimensions du plan correspondant à un paramètre et chaque point représentant un objet dans l'espace à deux dimensions.

### 3.4. Sélection des paramètres optimaux et classification

Les essais réalisés en utilisant les 208 paramètres n'étant pas concluants, il a été nécessaire de réduire le nombre de paramètres en sélectionnant ceux permettant d'obtenir la meilleure séparabilité entre les classes. L'outil *Sample Editor* proposé par eCognition a été utilisé pour identifier les paramètres optimaux (Figure 8) : il permet de comparer les histogrammes de distribution de deux classes pour chacun des paramètres à partir des échantillons sélectionnés. Ainsi, pour chaque duo de classes difficilement séparables, la séparabilité des histogrammes de distribution a été analysée et le nombre de paramètres a été réduit en (1) retenant les paramètres engendrant une bonne séparabilité entre les classes, (2) écartant ceux qui provoquaient des confusions (Tableau 2).

Ainsi, 111 paramètres optimaux ont été retenus pour réaliser la classification *Nearest Neighbour*. Pour la classification avec les algorithmes SVM, KNN et *Bayes*, il s'est avéré qu'un nombre de paramètres encore plus réduit permettait d'obtenir de meilleurs résultats. Ainsi, différentes combinaisons de paramètres ont été testées pour chacun des trois algorithmes pour arriver à un résultat final le plus satisfaisant possible quant à la précision globale de bon classement. Le nombre de paramètres a ainsi été réduit à 19 paramètres pour les algorithmes SVM et KNN, et 6 paramètres pour la classification bayésienne.



**Figure 8** : fenêtre *Sample Editor* d'eCognition avec comparaison des classes 'urbain (1)' et 'forêt (1)'. Les paramètres sont listés dans la colonne de droite. Les histogrammes représentent la distribution des valeurs pour chaque classe, en noir la classe 'urbain (1)', en bleu la classe 'forêt (1)'.

Classes à différencier	Paramètres donnant une bonne séparabilité	Paramètres engendrant une confusion
urbain (2) / forêt	mean anisotropy mean degree_purity mean depolarization_index mean entropy mean p1 mean pedestal_height mean polarization_fraction mean scattering_predominance mean DERD	mean Pauli_2 circular mean Pauli_2
urbain / forêt	mean SERD	max diff
forêt / cultures (2)	mean ratio_VH_VV mean entropy_shannon_1 StdDev alpha3	StdDev RVI
cultures (1) /cultures (3)	mean alpha mean Pauli3 mean Touzi_alpha	mean entropy_shannon_l
cultures (2) / cultures (3)	mean ratio_VV_HH mean ratio_HH_VV mean beta2 mean beta3 StdDev polarisation fraction	mean entropy_shannon_l mean Pauli_1
cultures (1) / vignobles	mean alpha1 mean alpha3 mean beta2 mean ratio_HH_VH mean ratio_VV_VH StdDev Pauli_2 StdDev Pauli_1 GLCM homogeneity Pauli_2 GLCM dissimilarity Pauli_2	mean Pauli_3

**Tableau 2 :** Paramètres de séparation et de confusion des classes déterminés suite à l'analyse réalisée avec l'outil *Sample Editor*.

## 4. Résultats

### 4.1. Paramètres polarimétriques optimaux

Suite aux résultats de la classification, certains paramètres polarimétriques sont apparus plus pertinents que d'autres pour classer l'image polarimétrique. Ainsi, certains paramètres (polarimétriques ou spécifiques à eCognition) sont apparus comme n'ayant aucun poids dans la classification. Il s'agit des paramètres issus des décompositions de Krogager, Van Zyl, Yamaguchi et An Yang et du SPAN (paramètre représentant la puissance totale du signal). Nous avons également pu remarquer que leur distribution, observée dans l'outil *Sample Editor*, était très restreinte, i.e. leurs histogrammes avaient un écart-type très faible. Des tests ont été relancés en ayant normalisé tous les paramètres par le span, et les résultats se sont révélés moins bons. De plus, la normalisation n'a pas permis d'améliorer le problème posé par la distribution des valeurs. Les histogrammes des décompositions de Freeman, Van Zyl, Yamaguchi et An Yang ne permettent pas une bonne différenciation des classes.

Les paramètres qui se sont avérés les plus pertinents pour la classification sont les paramètres issus de la décomposition H/A/alpha et de la décomposition de Touzi, les paramètres de Praks et Colin, les bandes du Pauli RGB et les images d'amplitude des quatre canaux de l'image.

Les paramètres de textures, tout en permettant d'améliorer la classification en précisant certaines classes comme la prairie, n'ont pas eu une influence de taille sur les résultats. Ceci est en contradiction avec les études précédentes comme Zhang *et al.*, 2009 ou Soheili Majd *et al.*, 2012. Il serait intéressant de tester la méthode sur d'autres zones d'étude. Les paramètres de texture ne sont peut-être pas assez diversifiés sur la présente zone d'étude pour permettre de faire une différence dans la classification. Les paramètres eCognition *hue, saturation, intensity, skewness* et *brightness* n'ont finalement pas été utiles à la classification.

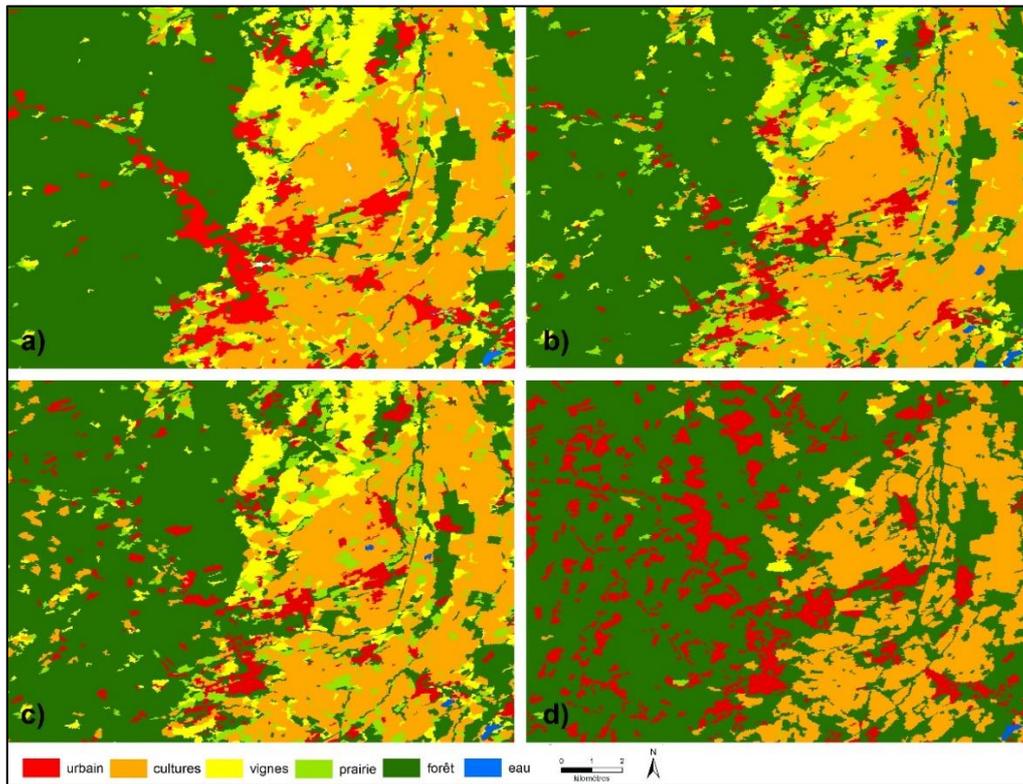
### 4.2. Classification Nearest Neighbour

Les meilleurs résultats ont été obtenus avec l'algorithme *Nearest Neighbour* (Figure 9). Après application de la méthode à l'ensemble de l'image ALOS PALSAR, le taux de précision totale de la classification calculé à partir de la matrice de confusion (Tableau 3) est de 69% et le coefficient de kappa de 0,61. Selon les catégories mises en place par Landis et Koch (1977), un kappa compris entre 0,40 et 0,80 indique un accord modéré entre la classification et la référence. Ceci peut en grande partie s'expliquer par une forte confusion entre les classes 'vignes', 'prairie' et 'cultures (1)'. Il est également notable que la classification d'images radar donne de manière générale de moins bons résultats que la classification d'images optiques, à partir de laquelle les catégories de Landis et Koch (1977) ont été définies.

Les classes 'forêt' et 'urbain' ont été bien détectées dans l'ensemble. On note cependant quelques cas de confusions avec une commission de la classe 'forêt' en défaveur de la classe 'urbain' (Tableau 4). En effet, la classe 'urbain' a souvent été confondue avec la forêt, certaines zones urbaines ayant une signature trop proche de celle de la forêt (mélange de vert et de rouge dans le 'Pauli RGB' correspondant à la classe 'urbain (2)'). La classe 'forêt' enregistre un taux de détection de 91%, les effets de reliefs ayant été correctement corrigés par les différentes classes de forêt utilisées.

Les classes 'vignes', 'prairie' et 'cultures (1)' ont souvent été confondus du fait de leur signatures très

similaires dans le 'Pauli RGB'. La classe 'vignes' enregistre un fort taux de commission et la classe 'prairie' un fort taux d'omission. Elle a en effet souvent été détectée comme 'cultures (1)' ou 'vignes'. La classe 'cultures (1)' a également souvent été détectée comme 'vignes'. Ces confusions peuvent être liées à des différences de structure de la végétation. Les zones de prairie classées comme 'vignes' pourraient ainsi correspondre à des prairies à herbe plus hautes, plus assimilables à de la lande ligneuse et qui auraient donc une rétrodiffusion de volume plus forte et une rétrodiffusion de surface moins élevée que la prairie où l'herbe est plus basse.



**Figure 9 :** Résultats des classifications : a) *Nearest Neighbour*, b) SVM, c) KNN, d) *Bayes*. Les classes 'urbain (1)' et 'urbain (2)' et les classes 'forêt (1)', 'forêt (2)', 'forêt (3)' et 'forêt (4)' ont été fusionnées respectivement dans les classes 'urbain' et 'forêt'. Les classes 'cultures (1)', 'cultures (2)' et 'cultures (3)' ont été fusionnées dans la classe 'cultures' pour permettre une meilleure comparaison avec la vérité terrain présentée en Figure 2.

		Référence								TOTAL
		Urbain	Cultures (1)	Cultures (2)	Cultures (3)	Vignes	Prairie	Forêt	Eau	
Classification	Urbain	34	1	1	0	2	3	8	0	49
	Cultures (1)	1	35	0	1	2	7	0	1	47
	Cultures (2)	1	1	10	0	15	1	0	0	28
	Cultures (3)	0	5	0	19	0	3	0	0	27
	Vignes	0	7	0	0	22	16	1	0	46
	Prairie	2	2	0	0	4	26	3	0	37
	Forêt	17	1	0	0	3	11	121	0	153
	Eau	0	1	0	0	0	3	0	9	13
TOTAL	55	53	11	20	48	70	133	10	400	

**Tableau 3 :** Matrice de confusion réalisée à partir de 400 points (i.e. entités créées dans un fichier de forme ponctuel) répartis aléatoirement sur l'image, le nombre de points attribué à chaque classe étant proportionnel à la surface occupée par celle-ci dans l'image. La validation a été réalisée sur la base de la BD OCS CIGAL de 2008, de l'image SPOT 5 du 25/04/2007 et du 'Pauli RGB' extrait de l'image ALOS PALSAR.

Les classes 'cultures (2)' et 'cultures (3)' enregistrent de très bons taux de détection (respectivement 90% et 95%). La classe 'cultures (3)' possède de faibles taux d'omission et de commission. La classe 'cultures (2)' est caractérisée par un très fort taux de commission engendré par des zones où la classification a été faussée par des perturbations du signal ('taches' plus claires ou rouges dans le 'Pauli RGB').

La classe 'eau' enregistre un faible taux d'omission mais un fort taux de commission. Les erreurs de commissions sont dues à des cas de confusion avec des zones de prairies ayant une signature similaire à celle de l'eau, indiquant une forte rétrodiffusion de surface. Les erreurs d'omission sont imputées au fait que certaines zones en eau ont été segmentées en différents objets en fonction des teintes prises sur le Pauli RGB (sur-segmentation). Ainsi, chaque partie de la zone en eau a été classée différemment. La sous-segmentation est également à l'origine de certaines erreurs : certaines zones comprises dans un même objet correspondent en réalité à différentes classes d'occupation du sol.

	Taux de commission	Taux d'omission
urbain	31%	38%
cultures (1)	26%	34%
cultures (2)	64%	10%
cultures (3)	30%	5%
vignes	52%	54%
prairie	30%	63%
forêt	21%	9%
eau	31%	10%

**Tableau 4** : Taux de commission et d'omission calculés à partir de la matrice de confusion.

#### 4.3. Classifications SVM, KNN et Bayes

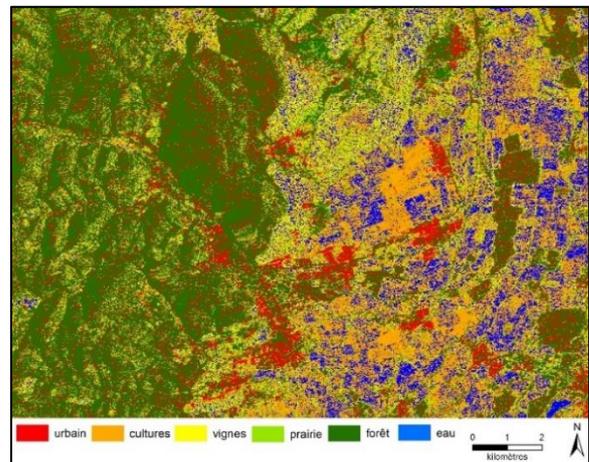
Les algorithmes SVM, KNN et Bayes montrent de moins bonnes performances que l'algorithme *Nearest Neighbour* avec des taux de précision totale respectifs de 60%, 56,2% et 44%. L'algorithme SVM, utilisé en mode linéaire avec un noyau C=10, ressort ainsi comme le plus efficace des trois. Le KNN, dont le résultat optimal a été obtenu avec K=3, montre un résultat proche de celui obtenu avec le SVM mais avec une moins bonne détection de l'urbain (sous-estimation à certains endroits, surestimation à d'autres, dues à la confusion avec la forêt). On y remarque également un mélange plus fort entre la classe 'vignes' et 'cultures (1)'. L'algorithme de Bayes montre un résultat bien en-dessous des deux autres algorithmes. Ces résultats peuvent s'expliquer en partie par le fait que tous les outils d'optimisation de la classification disponibles sous eCognition sont basés uniquement sur une simulation de la classification *Nearest Neighbour*, les autres algorithmes n'ayant été implémentés que très récemment.

#### 4.4. Comparaison avec l'approche pixel

Afin d'évaluer l'apport de l'analyse orientée-objet dans la classification, une classification par pixel a été réalisée par le biais du logiciel ENVI 5.1 (Figure 10). Le résultat de la classification s'avère moins bon que le

résultat de la classification *Nearest Neighbour* réalisée sous eCognition. Il enregistre un taux de précision totale de 40,7%. Le résultat est fortement affecté par le bruit de l'image radar. Ainsi, les zones de forêt sont affectées par du bruit créée par des pixels classés en 'urbain' et les zones de vignes sont mélangées avec des pixels classés en 'prairie'. On remarque aussi des erreurs de classification liées aux effets de relief dans les zones d'ombre des versants exposés à l'Est. Celles-ci sont classées dans la classe 'vignes' au lieu de la classe 'forêt'.

Par ailleurs, la classification apparaît comme plus représentative des mécanismes physiques de rétrodiffusion plutôt que des classes thématiques de la typologie. Ainsi, les différences dans la structure des cultures ressortent et une majorité des zones de 'cultures (1)' a été classée dans la classe 'eau' du fait de la présence d'une forte rétrodiffusion de surface. La classe 'cultures (3)' a de ce fait été très bien détectée.



**Figure 10** : Résultat de la classification par pixels.

### 5. Conclusion et perspectives

Dans cette étude, une carte d'occupation du sol d'une partie de la plaine d'Alsace et du massif vosgien a été produite à partir (1) de 76 paramètres polarimétriques extraits d'une image ALOS PALSAR en polarisation quadruple et (2) d'une méthode de classification supervisée et semi-automatique orientée-objet. Plusieurs algorithmes de classification ont été testés et l'algorithme *Nearest Neighbour* est ressorti comme donnant les meilleurs résultats.

Ainsi, neuf classes d'occupation du sol ont été cartographiées à partir des paramètres polarimétriques et d'une segmentation de l'image issue de la décomposition de Pauli. L'évaluation de la classification de l'image ALOS par le *Nearest Neighbour* montre des résultats encourageants (69% de taux de précision totale et un coefficient kappa de 0,61). Sur les neuf classes cartographiées, trois ont été très correctement détectées : la forêt, l'urbain et l'eau. D'autres classes se sont retrouvées très mélangées du fait de la similarité de leur signature polarimétrique : les zones de vignobles, les prairies et les zones de cultures. Cependant, trois classes non visibles sur les données de référence ont pu être identifiées par le biais du Pauli RGB.

L'avantage de la méthode développée est qu'elle est très facilement reproductible. La combinaison de paramètres utilisée en entrée de la classification est calculable sur n'importe quelle image SAR en polarisation quadruple. De plus, la méthode ne nécessite pas la mise en place de règles, donc pas de calcul de seuils. Seule la sélection d'échantillons représentatifs reste un facteur limitant car les échantillons ne peuvent pas être importés *a priori*. Les différents tests réalisés montrent que la sélection des échantillons reste déterminante dans le résultat.

Les essais de classification par pixel réalisés montrent également que l'approche orientée-objet est plus adaptée que l'approche pixel pour la classification d'images polarimétriques. La segmentation incluse dans la méthode orientée-objet permet de s'affranchir du bruit contenu dans l'image radar, visualisable sur le Pauli RGB. Les objets ont permis d'éviter la présence de pixels isolés, le résultat apparaissant comme moins continu dans la classification par pixel.

L'étape de segmentation apparaît comme déterminante dans les résultats obtenus. Elle est à l'origine de certaines erreurs de classification. Pour pallier à ce problème, il est envisageable de réaliser la segmentation sur d'autres paramètres, de la guider grâce à une couche thématique 'experte' ou d'utiliser un algorithme de segmentation autre que la segmentation multi-résolution. Par ailleurs, la méthode pourrait également être testée en utilisant d'autres logiciels, comme l'ORFEO Toolbox par exemple, qui permet d'intervenir plus directement sur les paramètres de la segmentation et des algorithmes de classification. Elle permettrait également de tester à nouveau certains algorithmes comme le SVM, qui s'est avéré très efficace dans de nombreuses études de la littérature scientifique. Il est également possible d'envisager l'utilisation d'autres paramètres qui n'ont pas été calculés sous eCognition. Ainsi, les paramètres de textures pourraient être calculés sur d'autres couches que celles du Pauli RGB.

Dans notre étude, aucune étape de post-traitement de la classification n'a été réalisée. L'inclusion de couches 'expertes' pourrait permettre d'améliorer le résultat de la classification. Ainsi, l'introduction d'un MNT pourrait permettre de distinguer les zones de prairies de la plaine des zones de pâturages ou de landes de montagne. L'utilisation de couches provenant de bases de données externes pourrait par exemple permettre de différencier la ripisylve de la forêt en fonction de leur proximité aux cours d'eau.

Pour finir, une étude plus approfondie des types d'occupation du sol présents sur la zone d'étude, via des campagnes de terrain et des comparaisons avec des données d'occupation du sol plus précises (comme le niveau 4 de la BD OCS CIGAL par exemple), paraît nécessaire pour pouvoir expliquer certaines confusions entre classes (e.g. confusion entre les classes 'vignes' et 'prairie'), mais aussi les caractéristiques spécifiques des classes 'culture (2)' et 'cultures (3)' repérées sur le Pauli RGB. Le test de méthodes plus robustes, comme le Random Forest, ou non-supervisées, comme le K-means, pourrait permettre d'améliorer la distinction de ces classes multi-apparences.

## Remerciements

Les images ALOS PALSAR ont été fournies gratuitement par l'agence spatiale japonaise (JAXA) dans le cadre du 4ème appel à projets de recherche pour les données ALOS (*4th ALOS Research Announcement*). Ce travail a été réalisé dans le cadre du projet TOSCA CES Theia 'Occupation des Sols Opérationnelle'.

## Références

- Alberga V., Satalino G., Staykova D. K., 2008. *Comparison of polarimetric SAR observables in terms of classification performance*. International Journal of Remote Sensing, 29 (14), 4129–50.
- An W., Xie C., Yuan X., Cui Y., Yang J., 2011. *Four-component decomposition of polarimetric SAR Images with deorientation*. IEEE Geoscience and Remote Sensing Letters, 8(6):1090–94.
- Avtar R., Wataru T., and Haruo S., 2013. *Full polarimetric PALSAR-based land cover monitoring in Cambodia for implementation of REDD Policies*. International Journal of Digital Earth, 6(3):255–75.
- Baghdadi N., Bernier M., Gauthier R., and Neeson I., 2001. *Evaluation of C-Band SAR data for wetlands mapping*. International Journal of Remote Sensing, 22(1):71–88.
- Banerjee B., Bhattacharya A., and Buddhiraju K.M., 2014. *A generic land-cover classification framework for polarimetric SAR images using the optimum Touzi decomposition parameter subset - An insight on mutual information-based feature selection techniques*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(4):1167–76.
- Bhattacharya B., and Touzi R., 2012. *Polarimetric SAR urban classification using the Touzi target scattering decomposition*. Journal Canadien de Télédétection, 37(4):323–332.
- Chen Y., He X., Wang J., and Xiao R., 2014. *The influence of polarimetric parameters and an object-based approach on land cover classification in coastal wetlands*. Remote Sensing, 6:12575–92.
- Cloude S.R., and Pottier E., 1997. *An entropy based classification scheme for land applications of polarimetric SAR*. IEEE Transactions on Geoscience and Remote Sensing, 35(1):68–78.
- Colin-Koeniguer E., Trouve N., Praks J., 2010. *A review about alternatives to classical polarimetric SAR parameters*. Proceedings of the 8th European Conference on Synthetic Aperture Radar (EUSAR), Aachen, Germany, 1–4.
- Collingwood A., Treitz P., Charbonneau F., Atkinson D., 2014. *Artificial neural network modeling of high arctic phytomass using synthetic aperture radar and multispectral data*. Remote Sensing, 6(3):2134–53.
- Corucci L., Meta A., and Coccia A., 2015. *An L-band fully polarimetric SAR system for vegetation classification*. Proceedings of the IEEE 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR), Singapore, Singapore, 558–60.

- Entezari I., Motagh M., Mansouri B., 2012. *Comparison of the performance of L-band polarimetric parameters for land cover classification*. Canadian Journal of Remote Sensing, 38(5):629–43.
- Freeman A. et Durden S. L., 1998. *A Three-Component Scattering Model for Polarimetric SAR Data*. IEEE Transactions on Geoscience and Remote Sensing, 36(3):963–73.
- Guillaso S., Schmid T., Lopez-Martinez J., D'Hondt O., 2015. *Application of a new polarimetric filter to RADARSAR-2 data of Deception Island (Antarctic Peninsula region) for surface cover characterization*. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XL-7(W3):1035–39.
- Huang L., Li Z., Tian B.-S., Chen Q., Liu J.-L., and Zhang R., 2011. *Classification and snow line detection for glacial areas using the polarimetric SAR image*. Remote Sensing of Environment, 115(7):1721–32.
- Krogager E., 1990. *New decomposition of the radar target scattering matrix*. Electronics Letters, 26(18):1525–27.
- Landis J. and Koch G., 1977. *The measurement of observer agreement for categorical data*. Biometrics, 33:159-174.
- Lee J.-S. et Pottier E., 2009. *Polarimetric radar imaging, from basics to applications*. CRC Press. Taylor and Francis Group, Boca Raton, USA. Optical Science and Engineering.
- Li X., Touzi R. Guo H., 2008. *Land cover characterization and classification using polarimetric ALOS PALSAR*. Proceedings of the 2008 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Boston, USA, 793-802.
- Niu X., and Ban Y., 2013. *Multi-Temporal RADARSAT-2 Polarimetric SAR data for urban land-cover classification using an object-based support vector machine and a rule-based approach*. International Journal of Remote Sensing, 34(1):1–26.
- Park S. E., Yamaguchi Y., Singh G., Yamaguchi S., and Whitaker A. C., 2014. *Polarimetric SAR response of snow-covered area observed by multi-temporal ALOS PALSAR fully polarimetric mode*. IEEE Transactions on Geoscience and Remote Sensing, 52(1):329–40.
- Pottier, E., and L. Ferro-Famil, 2012. *PolSARPro V5.0, an ESA educational toolbox used for self-education in the field of POLSAR and POL-INSAR data analysis*. Proceedings of the 2012 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Munich, Germany, 7377–80.
- Praks J., Koeniguer E.C. et Hallikainen M.T., 2009. *Alternatives to target entropy and alpha angle in SAR polarimetry*. IEEE Transactions on Geoscience and Remote Sensing, 47(7):2262–74.
- Qi Z., Yeh A. G. O., Li X., and Lin Z., 2010. *Integrating object-oriented image analysis and decision tree algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR imagery*. Proceedings of the 2010 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Honolulu, USA, 3098–3101.
- Rodrigues A., Corr D.G., Pottier E., Ferro-Famil L., and Hoekman D., 2003. *Land cover classification using polarimetric SAR data*. Proceedings of the ESA-ESRIN Workshop on Applications of SAR Polarimetry and Polarimetric Interferometry, Frascati, Italy.
- Schmid T., Lopez-Martinez J., Guillaso S., D'Hondt O., Koch M., Mink S., Nieto A., and Serrano E., 2015. *Distribution of glacial and periglacial features within ice-free areas surrounding Maxwell Bay (South Shetland Islands) using polarimetric RADARSAT-2 data*. Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Milan, Italy, 3458–61.
- Soheili Majd M., Simonetto E., and Polidori L., 2012. *Maximum likelihood classification of single high-resolution polarimetric SAR images in urban areas*. Photogrammetrie, Fernerkundung, Geoinformation, 2012(4):395–407.
- Soheili Majd M., Simonetto E., and Polidori L., 2014. *Polarimetric SAR image classification on urban area using a subset selection method*. Proceedings of the 34th European Association of Remote Sensing Laboratories (EARSeL) Symposium, Warsaw, Poland, 27–33.
- Surek G., and Nádor G., 2015. *Monitoring of damage in sunflower and maize parcels using radar and optical time series data*. Journal of Sensors, 2015.
- Touzi R., 2007. *Target scattering decomposition in terms of roll-invariant target parameters*. IEEE Transactions on Geoscience and Remote Sensing, 45(1):73–84.
- Trimble, 2013. *Trimble eCognition Developer Reference Book*. Trimble Germany GmbH.
- Van Zyl, J. J., 1989. *Unsupervised classification of scattering behavior using radar polarimetry data*. IEEE Transactions on Geoscience and Remote Sensing, 27:36–45.
- Varghese A. O., Suryavanshi A., and Joshi A. K., 2016. *Analysis of different polarimetric target decomposition methods in forest density classification using C band SAR data*. International Journal of Remote Sensing, 37(3):694–709.
- Wang, S., Liu K., Pei J., Gong M., and Liu Y., 2013. *Unsupervised classification of fully polarimetric SAR images based on scattering power entropy and copolarized ratio*. IEEE Geoscience and Remote Sensing Letters, 10(3):622–26.
- Yamaguchi Y., Moriyama T., Ishido M., and Yamada H., 2005. *Four-component scattering model for polarimetric SAR image decomposition*. IEEE Transactions on Geoscience and Remote Sensing, 43(8):1699–1706.
- Zou T., Yang W., Dai D., and Sun H., 2010. *Polarimetric SAR image classification using multifeatures combination and extremely randomized clustering forests*. EURASIP Journal on Advances in Signal Process, 4:1–12.