

# QUANTIFICATION ET CARTOGRAPHIE DE LA STRUCTURE FORESTIERE A PARTIR DE LA TEXTURE DES IMAGES PLEIADES

Benoît Beguet<sup>1,2</sup>, Nesrine Chehata<sup>1</sup>, Samia Boukir<sup>1</sup>, Dominique Guyon<sup>2</sup>

1 : ENSEGD/Université de Bordeaux, laboratoire G&E (EA 4592), Pessac, benoit.beguet@ipb.fr

2 : INRA, UMR1391 ISPA, Villenave d'Ornon

## Résumé

Cette étude montre le potentiel de l'information texturale des images à très haute résolution spatiale Pléiades pour la quantification et la cartographie de la structure forestière des peuplements de pin maritime du sud-ouest de la France (massif forestier landais). Une première étape montre qu'il est possible d'estimer, par régressions linéaires multiples, les variables de structure forestière (comme le diamètre des couronnes ou la hauteur des arbres) à partir d'un ensemble d'attributs de texture automatiquement sélectionnés parmi un grand nombre de paramétrages possibles. La classification de l'image est ensuite effectuée en utilisant l'algorithme des forêts aléatoires (RF) pour discriminer cinq classes de structure forestière avec une approche hiérarchique. L'importance de variable des RF est utilisée pour la sélection des attributs de texture. Les résultats montrent l'intérêt de l'automatisation du processus et de l'utilisation conjointe des deux résolutions des images Pléiades (mode panchromatique et mode multispectral) pour dériver les attributs de texture les plus performants pour détecter de fines variations de structure forestière.

**Mots-clés :** Classification, Sélection de variables, forêts aléatoires, Texture, Forêt, Pléiades, Très haute résolution spatiale

## Abstract

*The potential of very high spatial resolution Pléiades image texture for forest structure quantification and mapping was assessed on maritime pine stands in south-western France. A preliminary step showed that multi-linear regressions allowed a reliable prediction of forest variables (such as crown diameter or tree height) from a set of features automatically selected among a huge number of texture features with various spatial parameterizations. The image classification was performed using the Random Forests (RF) ensemble classifier in order to discriminate five forest structure classes using a hierarchical approach. The RF-variable importance is used for texture feature selection. The results highlight the contribution of process automation and the need for a joint use of both Pléiades image resolutions (panchromatic and multispectral) to derive the best performing texture features.*

**Keywords:** Classification, Feature selection, Random forest, Texture, Forestry, Pléiades, Very high spatial resolution

## 1. Introduction

Les images à Très Haute Résolution (THR) spatiale donnent accès à une description de la structure forestière, au sens de la distribution des dimensions des arbres, en exploitant sa forte relation avec la texture des images quand la taille du pixel est inférieure à la dimension des arbres. Cette perspective répond au fort besoin d'inventaires fins et spatialisés de la ressource forestière et de ses changements dus à la gestion forestière, à une modification dans l'usage du sol ou suite à des événements catastrophiques (type tempête).

Notre étude a pour but d'évaluer le potentiel des images THR Pléiades et tout particulièrement de leur information texturale pour caractériser et cartographier de manière fine la structure forestière. Sont ciblés les peuplements forestiers traités en futaie régulière pure, c'est à dire constitués d'arbres d'une seule espèce et du même âge ou presque (peuplement équienne), à l'instar de ceux de pin maritime du massif forestier landais (sud-ouest France) qui, couvrant près d'un million d'hectares, ont une forte importance économique. Nous avons deux objectifs complémentaires. Le premier vise l'estimation de variables de structure forestière (grandeurs dendrométriques telles que diamètre des couronnes, hauteur, diamètre des troncs, densité ou espacement

des arbres) via une modélisation de leur relation avec des attributs de texture. Si les erreurs d'estimation ne sont pas trop fortes devant l'étendue de ces variables, on peut espérer identifier plusieurs classes de structure forestière couvrant tout le cycle de développement des peuplements. Le second objectif vise alors à identifier différents stades de développement des peuplements (du renouvellement à la maturité) à l'aide d'une classification d'image au niveau pixel de façon à produire une information forestière spatialisée la plus fine possible.

L'analyse de texture d'image THR appliquée aux problématiques forestières peut être divisée en trois familles principales (Maillard, 2003) : les méthodes basées sur les ondelettes (Van Coillie *et al.*, 2007 ; Regniers *et al.*, 2013) ou sur la transformée de Fourier (Couteron *et al.*, 2005 ; Proisy *et al.*, 2007), l'utilisation des variogrammes (St-Onge *et al.*, 1997 ; Song *et al.*, 2010) et enfin l'extraction des attributs de texture issus des matrices de co-occurrence (GLCM).

Nous avons choisi d'exploiter la texture sur la base des matrices de co-occurrence qui sont très utilisées (Kayitakire *et al.*, 2006 ; Castillo *et al.*, 2010 ; Boukir *et al.*, 2013 ; Chehata *et al.*, 2014 ; Beguet *et al.*, 2014). Leur principal inconvénient est le grand nombre de valeurs possibles des paramètres spatiaux à explorer. Pour remédier à ce problème, nous proposons une approche automatique qui consiste à sélectionner parmi

un très grand nombre d'attributs de texture (avec une grande diversité de paramétrage), un ensemble réduit d'attributs qui sont complémentaires entre eux et adaptés à l'application considérée. Ceci permet d'exploiter au maximum le potentiel des images Pléiades et de combiner les deux résolutions (panchromatique et multispectrale). Une méthodologie de sélection d'attributs de texture propre à chacun des deux objectifs visés est développée.


L'étude a été réalisée sur des peuplements de pin maritime (*Pinus pinaster* Ait.) du massif forestier landais. Pour tester la robustesse des méthodes développées et évaluer l'apport de l'imagerie Pléiades, elle s'appuie sur deux jeux d'images acquis sur le même site à deux dates différentes.

## 2. Site d'étude et données

Le site d'étude (Tagon-Marcheprime) couvre une surface de 80 km<sup>2</sup> entre Bordeaux et Arcachon. Comme généralement dans le massif landais, la sylviculture du pin maritime y est dynamique : les peuplements sont purs et équiennes ; ils sont renouvelés par semis en ligne ou plantation ; vers l'âge de 50 ans ils sont exploités en coupe rase ; entre temps ils sont éclaircis périodiquement (Maugé, 1987).

Deux jeux d'images Pléiades ont été acquis les 26 juin et 8 août 2012 en modes panchromatique (Pan, produit image ré-échantillonné à 0,50 m) et multispectral (MS, ré-échantillonné à 2 m, quatre bandes spectrales : bleu, vert, rouge et proche infra-rouge).

Une campagne de mesures *in situ* a été menée durant l'été 2012 à la fin de la période annuelle de croissance sur un grand nombre de peuplements de pin maritime (n=111) couvrant une large gamme de structure sur quasiment tout le cycle de développement (de l'âge de 3-4 ans à la maturité). Les variables mesurées sont : la hauteur des arbres (Ht, variant de 1,7 à 26,2 m), le diamètre des couronnes (Cd, de 0,77 à 10,69 m), le diamètre des troncs à 1,30m (Dbh, de 0,02 à 0,56 m), la densité des tiges (Nah, de 150 à 6729 arbres/ha). Un indicateur de l'espacement entre les arbres est calculé par transformation non linéaire de la densité (Sp, de 1,31 à 8,77 m). Les arbres mesurés dans chaque peuplement sont inclus dans un carré de 20 m x 20 m représentatif de la structure forestière dans un voisinage englobant de 80 m x 80 m. Pour chaque peuplement, un échantillon d'image centré sur la placette d'une taille de 60 m x 60 m est considéré (soit 120 pixels pour Pan et 30 pixels pour MS).



**Figure 1** : Imagettes panchromatiques et classes de structure forestière associées.

C1 : pas d'arbres visibles, en mutation (coupe rase, reboisement en cours ou récent, âge  $\leq$  3 ans environ) ;  
 C2 : arbres visibles, rangs visibles, Cd < 1 m ;  
 C3 : 1 m < Cd < 2,5 m, rangs visibles  
 C4 : 2,5 m < Cd < 4,5 m, rangs non visibles ;  
 C5 : Cd > 4,5 m.

En complément, 200 autres peuplements ont été reconnus par photo-interprétation visuelle des images en panchromatique pour constituer une base de données de référence pour la classification. Cinq classes de structure forestière ont été considérées pour décrire les stades de développement, elles sont représentatives de la dimension des couronnes (Cd) et de la distribution spatiale des arbres. Elles sont décrites en Figure 1.

## 3. Méthodologie

Les attributs de texture utilisés sont deux du premier ordre, moyenne et variance locale, et huit du second ordre, dérivés des matrices de co-occurrence (GLCM) et définis dans Haralick *et al.* (1973). Ces derniers (énergie, entropie, corrélation, inverse difference, inertia, cluster shade, cluster prominence, Haralick's Correlation) sont les plus couramment utilisés en télédétection forestière (Kayitakire *et al.*, 2006 ; Castillo *et al.*, 2010 ; Beguet *et al.*, 2014). Les attributs ont été calculés avec une vaste gamme de paramétrage spatial : rayon de la fenêtre de calcul ( $r$ ), orientation ( $o$ ), magnitude du déplacement ( $d$ ). Le nombre de niveaux de quantification a été fixé à 8 pour tous les attributs de texture. Ces attributs sont calculés sur chacune des bandes spectrales MS ainsi que sur la bande panchromatique, avec des gammes de paramètres adaptés présentées dans le Tableau 1. Les attributs Pan sont ré-échantillonnés après calcul à la résolution MS.

	$r$ (pixel)	$d$ (pixel)	$o$ (degrés)
<b>Pan</b>	5-25 ; pas : 5	1-10 ; pas : 1	0-135 ; pas : 45
<b>MS</b>	3-12 ; pas : 3	1-4 ; pas : 1	0-135 ; pas : 45

**Tableau 1** : Gammes de variation des paramètres spatiaux des GLCM.

L'idée principale, commune aux deux objectifs, est d'optimiser de manière automatique le paramétrage des attributs de texture (Beguet *et al.*, 2014). Cela est fait dans les étapes de sélection de variables parmi tous les d'attributs de texture possibles, plusieurs milliers, correspondant aux dix attributs définis précédemment, calculés sur toutes les données Pan et MS (soit deux résolutions spatiales et 5 bandes spectrales) pour chaque combinaison de paramètres spatiaux.

### 3.1 Modélisation des variables forestières

Des régressions linéaires multiples sont appliquées entre chacune des variables forestières d'intérêt et un ensemble d'attributs de texture image. Une méthode de sélection de variable adaptée aux régressions multiples est donc appliquée afin de trouver un sous-ensemble d'attributs de texture le plus représentatif de la variable de structure forestière concernée (en termes de R<sup>2</sup> et de RMSE, erreur quadratique moyenne, obtenue par validation croisée, c'est-à-dire prédiction d'une observation par modélisation sur les 110 autres (notée LOO RMSE)). Le sous-ensemble d'attributs obtenu se doit d'être à la fois équilibré, en terme d'importance relative, et exempt de colinéarité (problème très perturbant en régression linéaire multiple). La méthode de sélection de variables nommée « Random PRiF », mise au point dans une précédente étude (Beguet *et al.*, 2014), a été appliquée. Cette méthode permet de sélectionner un ensemble d'attributs complémentaires en minimisant grandement la colinéarité. Pour chaque

variable de structure forestière, un ensemble de 5 attributs de texture est sélectionné parmi l'ensemble des attributs de texture (MS et Pan) pour modéliser les différentes variables forestières.

### 3.2 Classification des stades de développement

La classification a été conduite de manière hiérarchique. Il s'agit, dans un premier temps, de discriminer la classe C1 (pas d'arbres visibles), qui correspond aux stades de mutation de la forêt avec un taux de couvert forestier quasi nul, des autres classes C2 à C5 qui correspondent aux stades ultérieurs de développement des peuplements (âge > 3 ans). Cette première classe C1 est donc très différente des autres classes. Cependant elle présente une très forte variabilité dans la composition et le développement de la végétation (et donc en radiométrie et en texture), ce qui rend sa reconnaissance difficile lorsque l'on cherche à différencier les cinq classes de manière directe. Une fois cette première discrimination effectuée, la classification des stades C2 à C5 est effectuée. L'approche hiérarchique permet d'identifier les surfaces C1 dans un premier temps, celles-ci sont ensuite masquées pour calculer à nouveau la texture uniquement sur les autres surfaces forestières. La dynamique radiométrique à traiter est alors réduite (concentrée sur les pixels de forêt), ce qui conduit à la création d'attributs GLCM plus adaptés, cela pour un même nombre de niveaux de quantification. Les deux résultats sont ensuite regroupés pour former la carte finale des 5 classes.

Deux étapes de sélection de variables sont alors nécessaires, une première étape pour trouver les attributs de texture qui discriminent le plus C1 des autres classes, puis une seconde étape de sélection de variables pour déterminer un ensemble d'attributs performant pour la discrimination entre les autres stades. La méthode de sélection de variable utilisée consiste à ordonner les attributs de texture en fonction de l'importance de variable mesurée dans un processus de classification par forêts aléatoires (ou Random Forests, RF) (Breiman, 2001). L'importance d'une variable est mesurée par la perte en précision de classification lorsqu'elle est modifiée aléatoirement (simulée comme absente). Cette sélection est faite sur un ensemble de 40 échantillons (choisis parmi les 111 peuplements mesurés *in situ*), ceci pour les deux étapes, à partir de l'ensemble complet des attributs de texture (MS et Pan).

La classification de l'image est faite par l'algorithme des forêts aléatoires (Breiman, 2001) en utilisant 100 arbres. Deux jeux d'échantillons indépendants sont utilisés pour l'apprentissage (n=100) et le test (n=100), ces jeux sont obtenus par photo-interprétation et sont indépendants des échantillons utilisés pour effectuer la sélection des attributs de texture.

Enfin, sur l'image classifiée, une régularisation spatiale est appliquée. Cette régularisation consiste à affecter à chaque pixel, l'étiquette majoritaire dans son voisinage. Le rayon de ce voisinage a été fixé à 4 pixels en résolution MS, ceci correspond à un diamètre de 16 m soit 2 fois l'espacement maximum entre arbres observé *in situ*.

## 4. Résultats et Discussion

### 4.1 Estimation des variables forestières

Les résultats obtenus pour les images Pléiades des mois de Juin et d'Août sont comparables, bien que sensiblement meilleurs en août.

Les meilleurs modèles de régression multiples obtenus pour chaque variable de structure forestière combinent des attributs de texture issus des deux résolutions avec divers paramétrages, pouvant différer d'une date à l'autre. Ceci confirme l'intérêt d'automatiser le processus afin d'avoir une combinaison optimale d'attributs multi-résolutions (Pan et MS) et multi-échelles (différents paramétrages spatiaux).

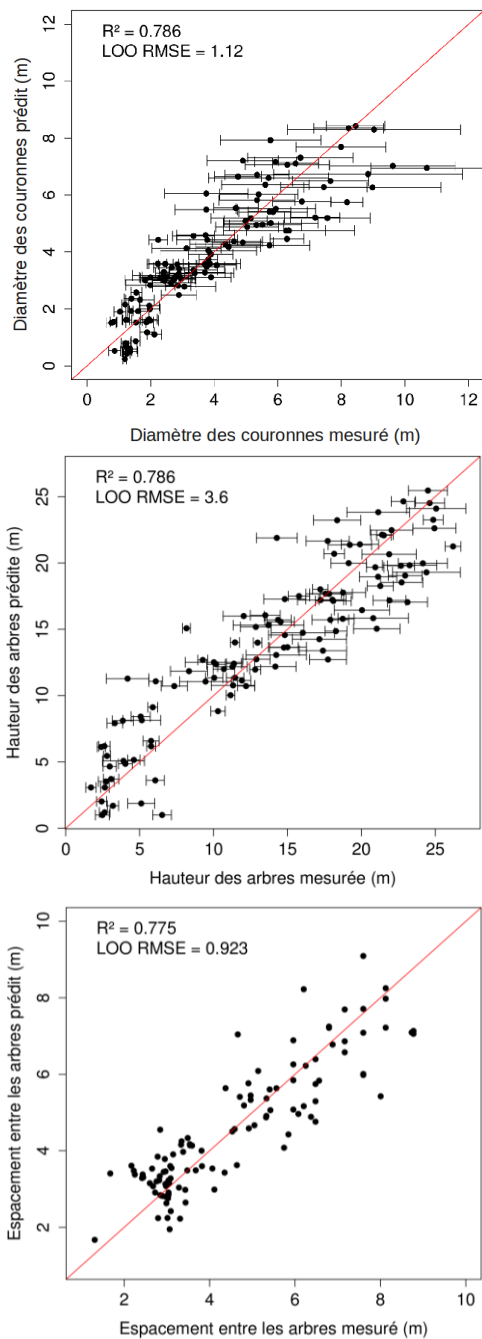
Un résumé des performances de prédiction des variables forestières est présenté dans le Tableau 2. Elles sont similaires pour les deux dates. Les plus faibles performances sur la densité Nah ( $R^2=0,54$  et  $0,63$ ) traduisent une non-linéarité de sa relation avec les attributs texturaux. Les meilleures précisions d'estimation (LOO RMSE) des autres variables sont les suivantes : ~1,1 m pour le diamètre des couronnes Cd (et ~0,062 m pour le diamètre des troncs Dbh, très corrélé avec le diamètre des couronnes), ~3,5 m pour la hauteur des arbres Ht et ~0,9 m pour l'espacement entre les arbres Sp.

Var. Forêt	R <sup>2</sup> multiple		LOO RMSE		Gamme de variation <sup>1</sup>
	Juin	Août	Juin	Août	
<b>Cd (m)</b>	0,79	0,81	1,12	1,10	0,77-10,7
<b>Sp (m)</b>	0,78	0,82	0,92	0,84	1,31-8,77
<b>Ht (m)</b>	0,79	0,83	3,6	3,1	1,7-26,2
<b>Nah (arbres/ha)</b>	0,54	0,63	639	586	150-6729
<b>Dbh (m)</b>	0,83	0,80	0,062	0,066	0,02-0,56

**Tableau 2** : Récapitulatif des meilleures performances de prédiction des variables de structure forestière obtenues par régressions linéaires multiples. Cd pour le diamètre des couronnes, Sp pour l'espacement entre les arbres, Ht pour la hauteur, Nah pour la densité et Dbh pour le diamètre des troncs.

<sup>1</sup> : Gamme de variation observée *in situ*

La Figure 2 présente les relations entre variables mesurées *in situ* et prédites à partir des meilleurs modèles. Cela pour les trois variables de structure forestière les plus importantes dans la formation de la texture dans les images : Cd, Ht et Sp. La dispersion des résidus varie selon les variables observées. Pour Sp cette distribution semble aléatoire ; pour Ht l'incertitude relative est forte pour des hauteurs inférieures à 5 m. Pour Cd un comportement hétéroscédastique (variance non constante le long de l'échantillon) est observé : plus le peuplement est mature, plus la variabilité locale du diamètre des couronnes est grande et donc plus l'incertitude de la prédiction sera importante. Cet effet est peut-être renforcé par une plus forte imprécision de sa mesure *in situ* pour les arbres les plus hauts (emploi d'une méthode optique). Les bonnes performances sur Cd, avec une RMSE ~10% de la gamme de variation sur tout le cycle de développement font espérer une identification précise des 5 stades par classification.



**Figure 2 :** Variables forestières mesurées et estimations prédites avec les meilleurs modèles, image de Juin. Les barres correspondent à  $\pm 1$  écart type

#### 4.2 Cartographie des stades de développement

Comme pour l'étape de modélisation, la sélection des attributs de texture par l'importance de variable des RF a conduit à un sous-ensemble d'attributs avec une grande diversité de paramétrages et combinant les deux résolutions. Cette observation est vérifiée dans les étapes de sélection d'attributs pour discriminer la classe C1 des autres et ensuite les quatre classes arborées (C2 à C5) entre elles. Ceci souligne la capacité de notre méthodologie à optimiser l'outil d'analyse de texture ainsi que l'utilisation des données Pléiades en fournissant des descripteurs multi-échelles et multi-résolutions. Les résultats de classification présentés sont ceux obtenus après l'étape de régularisation. Il est

à remarquer que si cette étape apporte une sensible amélioration d'un point de vue visuel, son gain sur les scores globaux de classification n'est pas très important (de l'ordre de 1%).

Le tableau 3 montre la matrice de confusion de la première étape de classification. La forêt en mutation (classe C1) est bien différenciée des autres stades forestiers, cela avec un indice kappa de 0,78 et une précision globale de 94%. On observe tout de même un fort taux d'erreur, aussi bien en omission (22%) qu'en commission (13%) pour cette classe. Ceci est vraisemblablement imputable en partie à la grande variabilité de la végétation à l'intérieur de cette classe.

Référence	Classification			% omission
	C1	Autres	Total	
<b>C1</b>	<b>13313</b>	3787	17100	22
<b>Autres</b>	1984	<b>70016</b>	72000	3
<b>Total</b>	15297	73803	89100	
<b>% commission</b>	13	5		<b>Précision globale = 0,94</b>
				<b>Kappa = 0,78</b>

**Tableau 3 :** Matrice de confusion pour la classification en deux classes : Forêt en mutation (C1) vs Autres classes (C2 à C5), nombre de pixels, image de juin.

Référence	Classification				Total	% omission
	C2	C3	C4	C5		
<b>C2</b>	<b>14508</b>	1115	474	103	16200	10
<b>C3</b>	1474	<b>15487</b>	2742	97	19800	22
<b>C4</b>	0	774	<b>16919</b>	1207	18900	10
<b>C5</b>	0	969	1026	<b>15105</b>	17100	12
<b>Total</b>	15982	18345	21161	16512	72000	
<b>% commission</b>	9	16	20	9		<b>Précision globale = 0,86</b>
						<b>Kappa = 0,81</b>

**Tableau 4 :** Matrice de confusion pour la classification des stades C2 à C5, nombre de pixels, image de juin.

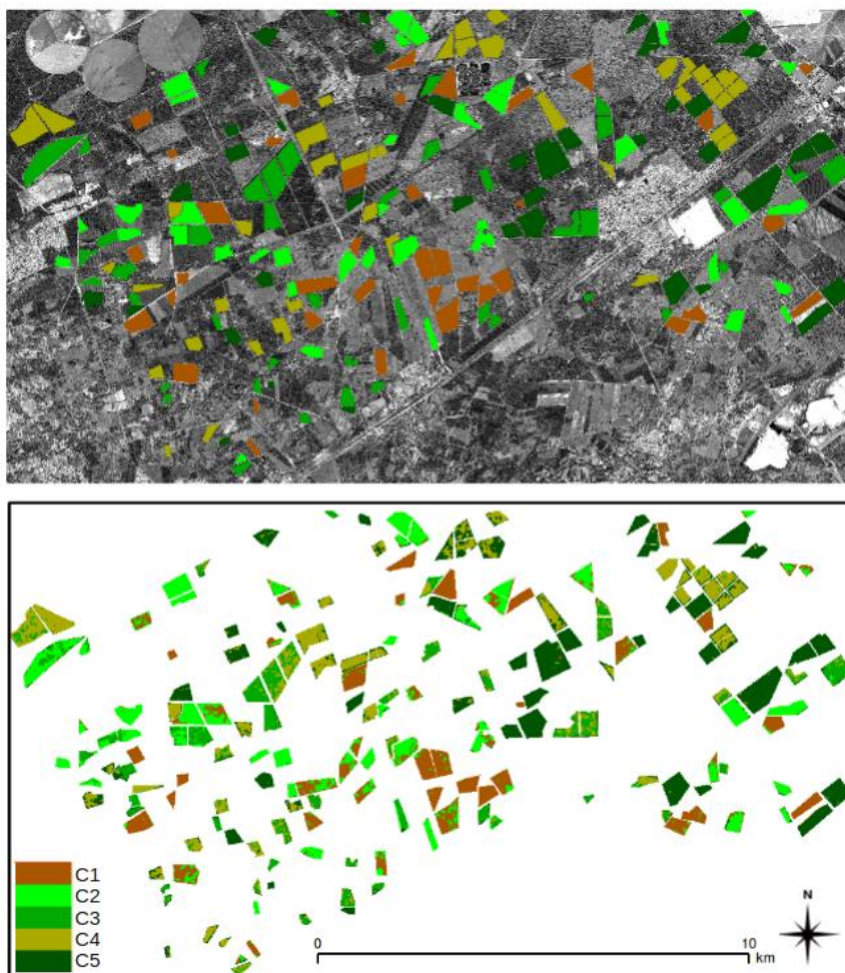
Référence	Classification					Total	% omission
	C1	C2	C3	C4	C5		
<b>C1</b>	<b>13313</b>	3787	0	0	0	17100	22
<b>C2</b>	1983	<b>12657</b>	1020	474	66	16200	22
<b>C3</b>	1	1473	<b>15487</b>	2742	97	19800	22
<b>C4</b>	0	0	774	<b>16919</b>	1207	18900	10
<b>C5</b>	0	0	969	1026	<b>15105</b>	17100	12
<b>Total</b>	15297	17917	18250	21161	16475	81900	
<b>% commission</b>	13	29	15	20	8		<b>Précision globale = 0,82</b>
							<b>Kappa = 0,78</b>

**Tableau 5 :** Matrice de confusion pour la classification complète des 5 stades par approche hiérarchique, nombre de pixels, image de juin.

Les résultats concernant la seconde étape de discrimination des 4 classes C2 à C5 sont présentés dans le Tableau 4. Les précisions de classification sont satisfaisantes avec un indice kappa de 0,8 et une précision globale de 85%. Les taux d'erreurs les plus importants concernent les classes intermédiaires C3 et C4, ce qui était attendu compte tenu de la nature floue de la frontière entre ces classes puisque la structure forestière présente un continuum. Ceci met en évidence la complexité ce type de cartographie.

Enfin, après combinaison des deux étapes de classification, nous obtenons la matrice de confusion présentée dans le Tableau 5. Le taux de bonne classification globale est de l'ordre de 81%, l'indice Kappa de 0,77. On obtient une amélioration de l'ordre de 10% en utilisant l'approche hiérarchique par rapport

à une classification directe en cinq classes. Ceci a permis d'améliorer considérablement les performances de discrimination des classes arborées C2 à C5. La cartographie produite est donnée en Figure 3 en comparaison avec les classes réelles.



**Figure 3 :** Images des parcelles de référence (sur fond d'image Pan) et de la classification hiérarchique des stades de développement par RF sur le jeu d'images de juin.

## 5. Conclusion

En conclusion, les résultats montrent le fort potentiel de la texture des images Pléiades pour modéliser des variables de structure forestière utiles à l'estimation de la ressource en bois et pour cartographier les stades de développement de peuplements, en particulier sur le massif landais de pin maritime où il a été évalué.

La méthodologie proposée permet d'optimiser l'exploitation de l'information texturale des images Pléiades en calculant des attributs de texture avec une grande diversité de paramétrages possibles et en combinant les deux résolutions panchromatique et multispectrale. Les meilleures combinaisons d'attributs de texture sont ensuite sélectionnées pour estimer les variables de structure forestière et pour la classification des stades développement.

Grâce à l'automatisation des procédures, l'intérêt est de ne faire aucune hypothèse *a priori* sur la relation entre structure forestière et texture d'image, qui peut être très dépendante des conditions d'observation satellitaire

(saison qui détermine la hauteur du soleil et le stade phénologique, angles de visée, par exemple). Ce type d'approche pourrait donc être transposé à d'autres applications et mériterait d'être testé sur des forêts plus complexes ou plus hétérogènes.

La bonne précision obtenue sur l'estimation des variables forestières comme le diamètre des troncs (à attribuer à sa forte relation allométrique à celui des couronnes), la hauteur et l'espacement laisse espérer une application opérationnelle des images Pléiades pour une cartographie fine de la biomasse forestière ou des volumes de bois. Néanmoins la précision sur la hauteur moyenne est moins bonne que celle obtenue sur la hauteur dominante (RMSE ~1 à 2 m) par corrélation d'image sur des observations stéréoscopiques Pléiades par Bélouard *et al.* (2014 dans ce numéro). Un usage en synergie des deux méthodes (analyse de texture et analyse tridimensionnelle sur images THR) viendrait maximiser la précision des estimateurs de la ressource forestière.

Pour la cartographie des stades de développement, une approche hiérarchique est proposée et validée. Une première étape permet de discriminer les peuplements forestiers en mutation (coupes rases, reboisements en cours ou très récents) des autres stades forestiers. Un taux de précision globale de l'ordre de 94% est obtenu. Cette étape est aussi intéressante dans la perspective de la détection de changements (coupe rase, nettoyage ou labour indicateurs d'un reboisement, ou encore dégâts de tempête). La classification en quatre grandes classes allant du stade de jeune peuplement (> 3 ans) à celui de peuplement mature (~50 ans) a atteint un score de précision globale de l'ordre de 85%. Ces résultats, établis en supposant que la localisation de la forêt de pin maritime et les limites de peuplement sont connues, sont très encourageants quant à des perspectives opérationnelles. En effet, à titre de comparaison, la carte des classes d'âge produite occasionnellement par l'IFN (service de l'Inventaire Forestier National) sur le département des Landes (BD Forêt Version 1 de l'IGN) par photointerprétation de prises de vue aérienne (résolution ~50 cm) différencie 3 classes d'âge dans la futaie pure de pin maritime.

La robustesse de la méthodologie proposée et la reproductibilité des hauts niveaux de précision atteints seront à confirmer avec une troisième image Pléiades, acquise dans des conditions très différentes : en hiver (20 Février 2013) avec une hauteur solaire moins élevée et une végétation du sous-bois sèche. L'application aux images multi-annuelles pourra permettre d'évaluer sur le massif landais la possibilité de cartographier des changements tels que des coupes rases, le mitage urbain ou les dégâts de tempête.

## Remerciements

Cette étude a été financée par le Conseil Régional d'Aquitaine et le CNES (Centre National d'Etudes Spatiales). Le CNES a fourni les images Pléiades (© CNES (2012), distribution Airbus DS / Spot Image). Ce travail est fondé sur l'utilisation de l'OrfeoToolBox (Inglada *et al.*, 2009). Les auteurs remercient Bernard Issenhut (INRA, Unité expérimentale Forêt Pierroton) pour la qualité des mesures terrain, Christian Germain (Laboratoire IMS, Bordeaux), Jordi Inglada (CESBIO, Toulouse) et Jean-Pierre Wigneron (INRA, Bordeaux) pour les discussions.

## Références

Beguet B., Guyon D., Boukir S., Chehata N., 2014. *Automated retrieval of forest structure variables based on multi-scale texture analysis of VHR satellite imagery*. ISPRS Journal of Photogrammetry and Remote Sensing, 96: 164–178.

Bélouard T., Py N., Maillet G., Guyon D., Meredieu C., Pausader M., Champion N. *Pinastéréo – Estimation de la hauteur dominante et de la biomasse forestière dans le massif des Landes de Gascogne à partir d'images stéréoscopiques Pléiades*. RFPT, ce numéro (soumis).

Boukir S., Orny C., Chehata N., Guyon D., Wigneron J. P., 2013. *Détection de changements structurels sur des images application en milieu forestier*. Traitement du Signal, 30:401-429.

Breiman L., 2001. *Random forests*. Machine Learning, 45(1):5-32.

Castillo M. A., Ricker M., De Jong B. H. J., 2010. *Estimation of tropical forest structure from spot-5 satellite images*. International Journal of Remote Sensing, 31-10:2767-2782.

Chehata N., Orny C., Boukir S., Guyon D., Wigneron J. P., 2014. *Object based change detection in wind-storm damaged forest using high resolution multispectral images*. International Journal of Remote Sensing. 35(13):4758-4777.

Coueron P., Pelissier R., Nicolini E. A., Paget D., 2005. *Predicting tropical forest stand structure parameters from Fourier transform of very high resolution remotely sensed canopy images*. Journal of Applied Ecology, 42:1121-1128.

Haralick R. M., Shanmugan K., Dinstein I., 1973. *Texture features for image classification*. IEEE Transactions Systems, Man and Cybernetics, 601-621.

Inglada J., Christophe E., 2009. *The Orfeo toolbox remote sensing image processing software*. IEEE International Geoscience and Remote Sensing Symposium, 4:IV-733–IV-736.

Kayitakire F., Hamel C., Defourny P., 2006. *Retrieving forest structure variables based on image texture analysis and ikonos-2 imagery*. Remote Sensing of Environment, 102:390-401.

Maillard P., 2003. *Comparing texture analysis methods through classification*. Photogrammetric Engineering & Remote Sensing, 69(4):357-367.

Maugé J.P., 1987. *Le pin maritime, premier résineux de France*, Editions IDF, Paris, 192p.

Proisy C., Coueron P., Fromard F., 2007. *Predicting and mapping mangrove biomass from canopy grain analysis using fourier-based textural ordination of ikonos images*. Remote Sensing of Environment, 109:379-392.

Regniers O., DaCosta J.-P., Grenier G., Germain C., Bombrun L., 2013. *Texture based image retrieval and classification of very high resolution maritime pine forest images*. Proceedings IEEE International Geoscience and Remote Sensing Symposium (IGARSS).

Song C., Dickinson M. B., Su L., Zhang S., Yaussey D., 2010. *Estimating average tree crown size using spatial information from ikonos and quickbird images: Across-sensor and across-site comparisons*. Remote Sensing of Environment, 114:1099-1107.

St-Onge B. A., Cavayas F., 1997. *Automated forest structure mapping from high resolution imagery based on directional semivariogram estimates*. Remote Sensing of Environment, 61:82-95.

Van Coillie F. M., Verbeke L. P., Wulf R. R. D., 2007. *Feature selection by genetic algorithms in object-based classification of ikonos imagery for forest mapping in flanders, belgium*. Remote Sensing of Environment, 110(4):476 -487.