

Liste des acronymes

NDVI	Normalized Difference Vegetation Index	RF	Random Forest
CIRAD	Centre International de Recherche Agronomique pour le Développement	TOA	Top Of Atmosphere
MTD	Maison de la TéléDétection	TOC	Top Of Canopy
UMR	Unité Mixte de recherche	SSD	Sum of Squared Difference
TETIS	Territoires, Environnement, TéléDétection et Information Spatiale	NCC	Normalized Cross-Correlation
CBD	Coffee Berry Disease	ENVI	Exelis Visual Information Solutions
LiDAR	Light Detection And Ranging	AFS4FOOD	Agroforestry for food security
SIG	Système d'information Géographique	SAF	Système Agro-Forestier
CNES	Centre National d'études Spatiales	NDVI	Normalized Difference Vegetation index
ACP	Analyse en composantes principales	CONT	Contrast
THRS	Tres Haute Résolution Spatiale	CORRE	Correlation
MNT	Modèle Numérique de Terrain	DISSI	Dissimilarity
MNS	Modèle Numérique de Surface	ENT	Entropy
MNH	Modèle Numérique de Hauteur	HOM	Homogeneity
OTB	Orfeo ToolBox	MEAN	Mean
SRTM	Shuttle Radar Topography Mission	SECMO	Second Moment
GCP	Ground Control Point	VAR	Variance
TP	Tie Point	VI	Vivrier
RMSE	Root Mean Square Error	THE	Théières
SVM	Support Vector Machine	CA1	Caféiers au soleil
		CA2	Caféiers sous ombrage
		BAN	Bananiers
		ARB	Couvert Arboré
		EUC	Plantation d'Eucalyptus

Table des matières

1	Contexte du stage et mission ingénieur	7
2	Le district de Murang'a au Kenya : un terrain d'étude complexe des dynamiques agroforestières	9
2.1	Géographie et topographie de la zone	9
2.2	Description de l'agriculture locale et de ses dynamiques : Etat de l'art	9
2.3	La télédétection : un œil global pour tenter de caractériser la complexité des paysages	11
3	Matériel et méthodes	13
3.1	Données issues de la télédétection	13
3.1.1	Modèle Numérique de Terrain (MNT) Shuttle Radar Topography Mission (SRTM) à 30m de résolution	13
3.1.2	Acquisition Worldview 2	14
3.1.3	Acquisitions Pléiades	14
3.2	Données issues des campagnes terrain	15
3.3	Méthodologie globale	15
3.4	Moyens logiciels à disposition durant la mission	16
4	Valorisation de l'information stéréoscopique contenue dans les triplets d'images Pléiades	17
4.1	Définition du principe de la stéréoscopie et état de l'art des applications par satellite	17
4.2	Etat de l'art des solutions logicielles actuelles	19
4.3	Pré-traitements réalisés sur l'imagerie Pléiades	20
4.3.1	Corrections radiométriques	21
4.3.2	Corrections géométriques	21
4.4	Traitement stéréoscopique des données sous ERDAS IMAGINE, solution propriétaire, payante et paramétrable	23
4.4.1	Influence de la différence angulaire sur la qualité du MNS	24
4.4.2	Résolution du MNS en sortie	24
4.4.3	Observations sur le Modèle Numérique de Surface (MNS) créé	25
4.4.4	Application à la zone entière	25
4.5	Transformation du MNS en Modèle Numérique de Hauteur (MNH)	25
4.6	Vérification de la précision en hauteur des données terrain	26
5	Classification des cultures agro-forestières par classification supervisée	28
5.1	Séparation de l'espace en classes thématiques	28
5.2	Limitations des données radiométriques de l'image Pléiades pour séparer ces classes	30
5.3	Introduction de données complémentaires à la radiométrie Pléiades	30
5.3.1	MNH – Informations sur la présence de hauts couverts	30
5.3.2	NDVI – Discrimination des parties végétales	31
5.3.3	Indices texturaux – Information sur les éléments structurants des objets	32
5.4	Etape de segmentation	32
5.5	Le choix de la classification supervisée	33
5.5.1	Supervisé ou non supervisé : les deux grands familles de classification	33
5.5.2	Jeu d'apprentissage	33
5.6	Choix de l'algorithme implémenté	34

5.6.1	Random Forest (RF)	35
5.6.2	SVM	35
5.6.3	Implémentation logicielle des algorithmes de classification	35
6	Résultats et interprétations	36
6.1	Résultats de la classification supervisée	36
6.1.1	Méthodes utilisées pour évaluer les résultats Création d'indicateurs quantitatifs et visuels	36
6.1.2	Test des différents algorithmes sur une acquisition Worldview 2 ou Pléiades	36
6.1.3	Introduction des données 3D dans la classification Pléiades	39
6.1.4	Utilisation conjointe de Pléiades et de Worldview 2	43
6.1.5	Application à tout Murang'a	44
6.2	Relations entre la classification et le relief de Murang'a	44
6.2.1	Répartition des cultures le long du gradient d'altitude	45
6.2.2	Répartition des cultures selon la pente locale du terrain	45
6.3	Perspectives d'utilisation pour les agronomes	46

Table des figures

2.1	Localisation de la région de Murang'a au Kenya	9
3.1	Empreinte au sol des acquisitions optiques Bleu – Triplet Pléiades 1 Vert – Triplet Pléiades 2 Mauve - Image Worldview 2	13
3.2	Apport du pansharpening pour la distinction d'éléments fins des cultures agraires : exemple de Worldview 2 (couleurs naturelles)	14
3.3	Méthodologie et chronologie du stage	16
4.1	Grandes étapes de la chaîne de traitement stéréo	20
4.2	Étapes de correction radiométrique des images Pléiades	21
4.3	Erreurs décroissantes sur un jeu de points de vérification Gauche : Erreur Pléiades/Worldview Droite : Erreur Pléiades/Pléiades	22
4.4	Zone de 1km ² utilisée pour les tests de stéréoscopie. Image Pléiades Pansharpening couleurs naturelles	23
4.5	Différentes combinaisons de duos stéréoscopiques appliquées à une zone de 50m de coté	24
4.6	Modèle numérique tri-stéréo obtenu avec les réglages de base Gauche : MNS brut et en relief Droite : Combinaison des deux	25
4.7	Comparaison du MNH extrait par deux méthodes différentes	26
4.8	Régression linéaire entre données terrain et données MNH extraites selon 4 méthodes différentes	27
5.1	Illustration des classes choisies par des exemples délimités sur l'image Pléiades	29
5.2	Création des indices dérivés du MNH	31
5.3	Discrimination de la végétation par le NDVI	31
5.4	Implémentation algorithmique de la chaîne de classification	35
6.1	Comparaison de précision de classification globale entre les données issues d'une seule acquisition Pléiades ou Worldview 2	37
6.2	Haut : Image Pansharpening Pléiades des zones de test Milieu : classification à partir des données Worldview 2 sur la base de l'algorithme au meilleur score Bas : classification à partir des données Pléiades sur la base de l'algorithme au meilleur score	38
6.3	Apport de la 3D pour la précision globale	39
6.4	Illustration de l'effet néfaste des données 3D sur la classification à l'aide de l'image Pléiades et du MNH	40
6.5	Haut : classification à partir des données Pléiades sans 3D sur la base de l'algorithme SVM linéaire Bas : classification à partir des données Pléiades avec 3D sur la base de l'algorithme SVM linéaire	41
6.6	Haut : classification à partir des données Pléiades sans 3D sur la base de l'algorithme Random Forest Bas : classification à partir des données Pléiades avec 3D sur la base de l'algorithme Random Forest	42
6.7	Cas exemple de prolifération de la classe bananier avec le passage à la 3D (Random Forest)	42
6.8	Importance des variables du Random Forest - Sélection des variables MNH	42
6.9	Evolution du taux de succès de chaque algorithme en fonction de la taille de l'échantillon d'apprentissage	43
6.10	Effet sur la précision globale de l'utilisation simultanée de Pléiades et Worldview 2	43
6.11	Répartition des classes le long du gradient d'altitude	45

6.12 Répartition des classes le long du gradient de pente 46

S.1 Représentation des classes de données sur les 2 premières composantes de l'ACP 78

1

Contexte du stage et mission ingénieur

Le présent travail, réalisé au sein de la Maison de la Télédétection (MTD), siège de l'Unité Mixte de recherche (UMR) Territoires, Environnement, Télédétection et Information Spatiale (TETIS) a pour objectif l'utilisation d'outils de télédétection innovants pour apporter de nouveaux résultats à deux projets de recherche nommés AFS4Food¹ et SAFSÉ², tous deux portés par le CIRAD.

Le projet AFS4food souhaite relier les Systèmes AgroForestiers (SAF) avec la sécurité alimentaire et le bien être des agriculteurs. Trois pays africains participent au projet : le *Kenya* (café), le *Cameroun* (cacao) ainsi que *Madagascar* (girofle). Bien que ces zones soient fondamentalement différentes, elles partagent un point commun : une agriculture de petits propriétaires dont la culture pérenne fournit la majorité des revenus du ménage. Pour l'administratif, les résultats diffusés, notamment la dynamique spatio-temporelle des systèmes de culture, pourront alors servir à la compréhension socioéconomique du territoire.

Le projet SAFSÉ se penche sur la gestion des systèmes agroforestiers. Il évalue les services écosystémiques rendus par ces systèmes en établissant une analyse intégrée tenant compte des compromis de production. Le projet est basé sur différents continents, notamment en zone humide (*Costa-Rica*) et en zone sèche (*Afrique sub-saharienne*). La finalité est de générer des connaissances et méthodologies utiles sur le fonctionnement de ces systèmes.

Si ces deux projets sont basés sur des échelles légèrement différentes, ils se recoupent néanmoins puisque le fonctionnement d'une parcelle agroforestière et les dynamiques agraires d'un paysage sont intimement liées. Cette notion multi-échelles est importante et explique en grande partie l'intérêt des techniques de télédétection pour répondre conjointement aux deux problématiques.

Dans les deux cas, ce stage est une conclusion aux projets, se clôturant fin 2015, et vise à apporter des résultats en matière de cartographie avec une méthodologie établie. Pourtant, au-delà de ces deux projets et de leurs livrables attendus, d'autres questions planent autour de l'utilisation de données 3D pour l'agriculture dans les pays en voie de développement. Nous nous pencherons plus spécifiquement ici sur les données 3D créées à l'aide de paires stéréoscopiques d'images satellites. Outre les questions méthodologiques qui vont se poser, c'est l'utilité de ces données qui doit être examinée dans des contextes économiques où les acquisitions pour la recherche doivent se justifier.

Les compétences au sein de l'UMR TETIS étant plus orientées vers la télédétection « 2D », l'approche du sujet est encore nouvelle, motivée par le potentiel offert par les triplets stéréoscopiques Pléiades, dont les images sont financièrement plus facilement accessibles pour la recherche. Une première étude prometteuse, appliquée à l'île de *Mayotte* dans le cadre d'un projet de Stéphane Dupuy financé par le Programme National de Télédétection Spatiale, a initié cette démarche exploratoire en 2014 (Dupuy et al., 2014). L'objectif pour le laboratoire est bien d'explorer les possibilités des méthodes de stéréoscopie pour éventuellement parvenir à simplifier des systèmes complexes difficilement compréhensibles par la télédétection classique seule. De ces recherches dépendra la décision de l'acquisition ou non de nouvelles images (pour le même projet ou d'autres projets). Ce mémoire d'ingénieur doit donc permettre de fournir certaines clés pour dresser un argumentaire remobilisable sur l'acquisition future de données

1. <http://afs4food.cirad.fr/>

2. <http://safse.cirad.fr/>

stéréoscopiques Pléiades. Il a aussi pour ambition de proposer de nouvelles méthodologies basées autour des données 3D.

La problématique directrice ainsi posée est alors :

Que peuvent apporter les données issues de la stéréophotogrammétrie par satellite dans un contexte de recherche en agriculture pour le développement ?

Les objectifs liés à cette question sont les suivants :

- Réaliser un état de l'art sur l'utilisation de ces techniques en agriculture
- Evaluer les possibilités des logiciels de traitement en photogrammétrie et tester les possibilités de l'un d'entre eux. Mettre en place une chaîne de traitement facilement réutilisable
- Trouver des solutions de mise en place une méthodologie de classification des cultures agricoles par des données Pléiades
- Quantifier l'apport des données 3D dans la qualité de la classification et émettre un avis sur leur utilité pour le présent domaine
- Apporter des premières interprétations agronomiques sur la région entière ainsi que d'autres pistes d'utilisation les résultats

L'utilisation des 6 mois du stage ingénieur a ainsi été partagée de manière quasi égale entre la mise en place des chaînes de traitement stéréoscopiques et l'application d'algorithmes de classification sur les données disponibles.

En parallèle, un autre stage en géomatique concernant l'utilisation de la tri-stéréoscopie pour la classification des terres agricoles camerounaises près de Bokito a eu lieu. Ses objectifs sont similaires et il a été possible d'échanger à de nombreuses reprises sur les difficultés communes et spécifiques ainsi que sur les perspectives d'utilisation de telles données. En plus de l'apport du maître de stage et d'internes à la MTD, la similitude entre nos deux travaux nous a permis d'injecter de nouvelles idées et de parfois voir les problématiques de notre travail sous un autre angle.

2.1 Géographie et topographie de la zone

Situé en *Afrique Centrale*, le *Kenya* est coupé par la ligne Equateur. Il partage des frontières avec l'*Ethiopie*, le *Soudan*, l'*Ouganda*, la *Somalie* et la *Tanzanie*. Au Centre-Est de ce pays aux climats et aux paysages extrêmement variés se situe le district de *Murang'a*, territoire montagneux au climat tropical humide (marqué par deux saisons des pluies). A l'intérieur du comté, notre zone d'étude mesure environ 25km de longueur sur la longitude et 10km sur la latitude. La figure 2.1 la situe précisément sur une carte

La topographie de notre zone, située à 1600m en moyenne et « coincée » entre la chaîne des *Aberdares* (altitude moyenne de 3600m) à l'Ouest et le *Mont Kenya* (culminant à 5199m) au Nord, est particulièrement marquée. On enregistre ainsi une différence d'altitude de 800m entre la bordure Est et la bordure Ouest de la zone, avec une pente continue. Un vallonnement intense se superpose à ce gradient, avec des « oscillations » plutôt orientées Nord/Sud de l'ordre de 200m sur moins d'un kilomètre.

Le choix de cette zone, intensivement étudiée dans nombre de travaux inclus dans SAFSÉ, AFS4food (Cirad, 2014) mais aussi dans d'autres projets, n'est pas anodin et repose en grande partie sur cette toposéquence et les conséquences qu'elle peut avoir sur l'organisation du paysage et des systèmes de culture locaux. Le présent travail a ainsi pour but d'apporter de nouvelles conclusions sur le terrain d'étude à l'aide de nouvelles méthodes, avec le support de bonnes connaissances multidisciplinaires de terrain.

2.2 Description de l'agriculture locale et de ses dynamiques : Etat de l'art

L'*Afrique sub-saharienne* fait face à de nouveaux défis en termes d'agriculture pour lesquels le *Kenya* ne fait pas exception. En raison de sa diversité climatique, des modes de culture et d'élevage variés cohabitent au *Kenya*. La zone de *Murang'a* fait partie de l'une des 4 grandes zones du pays marquées par la culture du caféier, dont l'exploitation est favorable en raison de l'altitude (entre 600 et 2000 m pour *Coffea arabica*) et des sols profonds tropicaux que l'on y rencontre. Dans cette zone afro-alpine, l'agro écologie ou agroforesterie et l'élevage sont fortement favorisés et c'est un mode de culture aujourd'hui très répandu. Les enjeux de l'agroforesterie au *Kenya*, et plus généralement en *Afrique*, sont nombreux. Bien que le café soit la

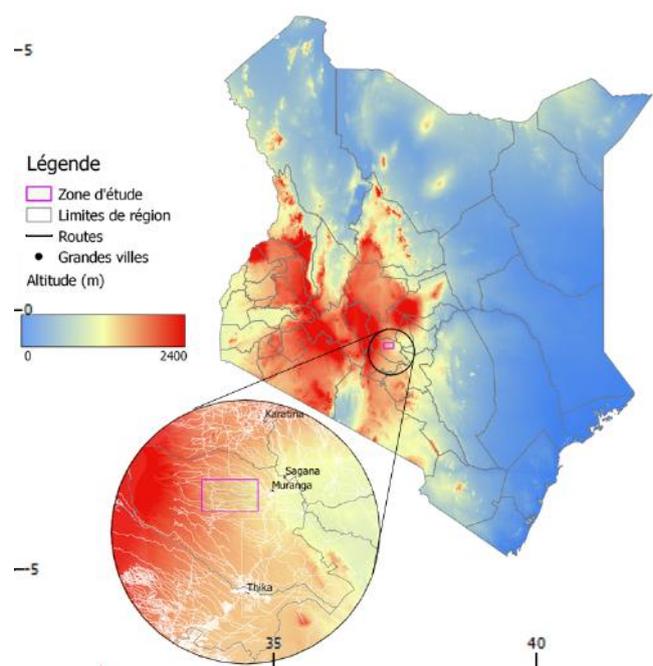


FIGURE 2.1 – Localisation de la région de Murang'a au Kenya

culture traditionnelle, le 20ème siècle fut surtout marqué, durant la colonisation britannique, par la monoculture de caféiers en plein soleil, avec forte utilisation en intrants (Barkaoui, 2010). L'après indépendance est alors marqué par l'adoption de nouvelles stratégies agricoles : des systèmes agro écologiques combinant le café, des arbres (le plus souvent Grevillea ou Aca-cia, pouvant être aussi utilisés comme du bois de chauffe et du fourrage) et parfois des cultures vivrières.

Pour rappel, on définit l'agroforesterie comme l'association d'une ou plusieurs cultures avec un couvert forestier. C'est un système stratifié possédant au moins 2 couches, mais ce nombre peut augmenter. L'agroforesterie a pour avantage de mutualiser la même terre pour plusieurs cultures, les associations peuvent de même être favorables à la productivité et diminuer les risques de maladies. Le besoin en pesticides mais surtout en engrais est diminué, une opération économiquement intéressante pour les petits producteurs pour qui ces produits sont un investissement compliqué. Dans notre cas, la caféiculture est le plus souvent associée à un mélange de plantes annuelles, de plantes pérennes ainsi que d'élevage. Le résultat est un système complexe avec de nombreuses interactions (Sibelet et al., 2012).

Bien que le café domine la région de Murang'a, les variations d'altitude et les pentes contraignantes que l'on y rencontre sont à l'origine de l'adoption de trois grands modes de systèmes de culture (Toko, 2013) :

- **La zone basse (Est)** en dessous de **1400m**, est principalement maraîchère et bananière. Le café y est cultivé sous ombrage, principalement de bananiers ou d'arbres fruitiers. Les fonds de vallée sont utilisés pour la production de légumes destinés à la vente locale ou à l'alimentation du ménage. On y retrouvera certaines cultures gourmandes en eau comme le taro.
- **La zone médiane (centre)**, entre **1400m** et **1800m** est la plus étudiée dans le cadre de notre projet. C'est la zone où le café Arabica est le plus présent. Il y est autant cultivé en monoculture, parfois sans aucun ombrage, qu'en associations forestières ou fruitières, avec tous les degrés de densité d'ombrage et de complexité de composition et de structure. Les exploitations agricoles se disposent le long des topo-séquences. On retrouve ainsi typiquement les maisons des agriculteurs et leur jardin en haut des pentes près des routes. En descendant, on retrouve les parcelles de caféiers, souvent délimitées par des haies d'arbres parallèles à la séquence (dues au partage lors de la succession père/fils des terres) puis en fond de vallée des cultures vivrières.
- **La zone haute (Ouest)**, au-dessus de **1800m**, est marquée par l'apparition soudaine des théiers et la disparition progressive des caféiers, avec des associations possibles café/thé dans la même parcelle.

L'élevage, quand-à lui, se retrouve à part plus ou moins égale dans les 3 zones délimitées. Les bananeraies sont présentes dans la plupart des exploitations cependant la plupart d'entre elles ne sont pas dans une parcelle dédiée mais sont souvent ponctuellement associées à d'autres cultures. D'après les enquêtes terrain réalisées par (Roucoux, 2014), il est difficile d'évaluer avec précision la superficie en bananiers. De plus, en raison de la croissance différenciée des bananiers, les plantations de bananiers génèrent un motif géométrique non régulier. De même pour les arbres fruitiers tels que les avocatiers et les manguiers, le plus sont souvent plantés individuellement, qui servent de consommation à la famille et ne sont pas vendus par les marchés locaux.

Les systèmes caféiers en place sont plus ou moins intensifs et correspondent au revenu principal. Les productions maraîchères et la production de lait permettent un complément de



revenu en plus d'assurer l'alimentation des familles. Cette complexité des cultures s'explique encore une fois historiquement par l'évolution des stratégies de production. La crise caféière dans les années 1990 (effondrement du prix du café en raison d'une offre mondiale en café trop importante) a remis en cause la viabilité économique de systèmes de culture basés uniquement sur le café. Les caféiers étant récoltés une ou deux fois par an, la limitation aux caféiers entraîne une importante précarité chez les agriculteurs, en plus de la crainte des maladies du café : Rouille du café dans les zones basses (*hemileia vastatrix*) et Coffee Berry Disease (CBD) dans les zones hautes (*colletotrichum kahawae*) qui ont été à l'origine de dégâts économiques importants (Crepuy, 2014). Afin de parer à cela, de nouvelles stratégies ont été adoptées, celles-ci dépendent de la position précise dans la toposéquence locale.

Il existe une importante résilience du café dans la zone *Murang'a*, bien que tout le Kenya soit en général touché. De plus en plus d'agriculteurs dans les zones basses se tournent vers l'élevage et les cultures vivrières, apportant des revenus en moyenne plus satisfaisants et surtout une sécurité financière et alimentaire accrue. La zone haute reste peuplée en caféiers en raison de sa qualité. Avec l'altitude la qualité du grain semble croître, le remplissage des grains prend plus de temps, ce qui a un effet bénéfique sur les arômes du café (Vaast et al., 2006). La culture du thé reste de même plus intéressante dans les zones au-dessus de 1800m, celui-ci pouvant être récolté chaque jour. Il est important de préciser que l'accès au foncier est difficile, la zone est remplie de petits producteurs possédant peu de surface et louant parfois une partie de leur terre, ce qui contraste avec les grandes fermes de café que l'on retrouve en se rapprochant des grandes villes.

(Roucoux, 2014) a ainsi établi en une typologie des systèmes de production, décrits ci-dessous :

- Les producteurs de café extensif non associé à des cultures vivrières, récolté une fois par an
- Les producteurs de café extensif associé à des cultures vivrières, souvent du haricot ou du maïs
- Les producteurs de café intensif à faible densité de plantation, récolté deux fois par an
- Les agriculteurs concentrés sur la conduite de cultures maraîchères, dont la principale est le sukuma
- Les agriculteurs concentrés sur l'élevage bovin, dont l'alimentation est basée sur la culture d'herbe napier

En terme de proportion, les deux cultures couvrant le plus de surface étaient dans cette étude le caféier (36% de la surface) et l'herbe napier (37% de la surface). Ces chiffres proviennent des différentes enquêtes terrain réalisées avec un échantillon de 50 exploitations agricoles, il serait donc intéressant de les comparer à d'éventuels résultats similaires acquis cette fois par télédétection.

2.3 La télédétection : un œil global pour tenter de caractériser la complexité des paysages

Comme nous l'avons vu au paragraphe précédent, cette mosaïque de cultures présente une complexité difficile à définir (enchevêtrement de plusieurs cultures entre elles, diversité d'itinéraires technique, limites entre parcelles floues) Pour cela, les outils de télédétection, principalement l'acquisition d'imagerie par satellite permettent d'obtenir une information spatiale précise à un instant donné, nous renseignant sur la structure des systèmes de culture.

Par rapport au travail de terrain précis mais coûteux, la télédétection offre la possibilité d'analyser exhaustivement des zones de plusieurs centaines de km ; le coût par rapport à la surface est grandement diminué. Cependant, là où la donnée de terrain récoltée par des enquêtes est déjà thématique, celle portée par les pixels d'une image satellite ne l'est pas. Beaucoup de techniques existent pour faire « parler » l'information contenue dans ces images (qui seront détaillées par la suite) mais ces techniques sont sujettes à des erreurs. Réaliser une cartographie de la zone détaillant les cultures en présence est possible mais l'erreur sur l'identification des parcelles doit être conforme à ce qui est attendu pour l'application prévue.

De nombreux outils de télédétection ont déjà été mobilisés par le passé dans la littérature mais ils le sont le plus souvent sur des zones beaucoup moins complexes, par exemple des monocultures ou des systèmes agroforestiers ordonnés. L'objectif de ce rapport n'est cependant pas d'évaluer la pertinence des images de télédétection usuelles pour la classification agricole. D'autres informations sont recherchées, l'idéal étant qu'elles proviennent de la même source que les images satellites afin de limiter les problèmes inhérents aux classifications multi-sources (calage entre données, comparaisons de valeurs radiométriques). La stéréoscopie par satellite répond à cette contrainte et propose une solution originale utilisable dès que l'on possède au moins deux images de la même zone prises sous des angles différents. Le but est de caractériser la structure verticale en mobilisant les concepts de la stéréoscopie, ce qui permet d'obtenir une carte de profondeur. Les limites du concept sont pourtant très facilement identifiables. Tout d'abord il est difficile d'espérer une précision comparable à ce que l'on obtient grâce au Light Detection And Ranging (LiDAR) qu'il soit aérien ou terrestre. Ensuite, seule la partie superficielle du couvert peut être analysée avec cette méthode (1 seule valeur par pixel), il semble quasi impossible par définition de mettre en évidence des strates. Un des objectifs de ce travail était d'évaluer jusqu'à quel niveau de caractérisation des parcelles il était possible d'arriver avec les données que nous possédons.

Il est à noter que nous souhaitons ici cartographier l'occupation et l'usage du sol, et donc les systèmes de culture, à une date donnée. Nous ne nous intéresserons pas aux aspects dynamiques, nécessitant l'acquisition d'images à différentes dates, ce qui ferait l'objet d'un projet d'étude à part tant techniquement que financièrement.

3.1 Données issues de la télédétection

Plusieurs sources de données de la télédétection sont utilisées dans le projet, dont des images optiques acquises à Très Haute Résolution Spatiale (THRS) par deux satellites différents (Pléiades et Worldview2) et un raster Modèle Numérique de Terrain (MNT) provenant de la mission SRTM. Si l'augmentation de la résolution permet théoriquement un apport supplémentaire d'informations, il convient de le nuancer par la difficulté à l'utiliser. Le choix de la THRS s'imposait cependant ici car il était motivé par la distinction d'éléments de petite taille tels que les caféiers (<3m de diamètre).



FIGURE 3.1 – Empreinte au sol des acquisitions optiques
Bleu – Triplet Pléiades 1
Vert – Triplet Pléiades 2
Mauve - Image Worldview 2

3.1.1 MNT SRTM à 30m de résolution

Les données acquises lors de la SRTM sont accessibles gratuitement pour quasiment toutes les terres émergées à la surface de la Terre, dans un premier temps à une résolution de 90m et maintenant à une résolution de 30m depuis fin 2014. Cette représentation 3D de la terre, entre modèle de terrain (altitude du sol) et modèle de surface (altitude du sol à laquelle on ajoute les éléments naturels ou artificiels présent par dessus) est traitée afin de s'approcher au plus de la topographie du sol seul. En effet, le sursol rehausse pour chaque pixel la valeur d'altitude mesurée. A 30m de résolution, il est cependant difficile de déterminer si l'effet du sursol est totalement corrigé. On retrouve de même certains défauts inhérents à l'acquisition. Un de ces défauts documentés (Australia Geoscience, 2011) se retrouve dans la région d'étude sous la forme d'une bande d'environ 20km de longueur et 500m de largeur à la texture granuleuse. On la retrouve sur le modèle à 30m mais aussi sur le modèle à 90m et il est difficile de savoir si ce défaut a une influence sur les traitements postérieurs. Il est à noter qu'outre de la précision planimétrique à $\pm 30m$, la précision altimétrique est de $\pm 16m$, ce qui représente la hauteur d'un arbre moyen. Prendre le SRTM comme référence n'est donc pas une décision anodine, elle induit une certaine marge d'erreur dans la précision de l'altitude.

La résolution spatiale du SRTM est très importante dans des zones à fort relief comme celle de notre étude car la variation réelle d'altitude au sein d'un pixel grossier (tel que 90m dans les

versions précédentes du MNT SRTM) peut être considérable alors que la valeur du-dit pixel est fixe. Il en résulte des décalages géométriques parfois importants lorsque l'on veut utiliser le modèle pour orthorectifier une image. Dans des zones à forte pente, cette erreur planimétrique peut atteindre 5 à 10m. Plus la précision du modèle numérique en entrée sera bonne, plus les erreurs ultérieures sur l'altitude seront gommées.

3.1.2 Acquisition Worldview 2

Acquisée en 2013, l'image Worldview 2 couvre une superficie d'environ 160km². Elle a été orthorectifiée sous ENVI sur la base du MNT SRTM à 30m de résolution spatiale. L'image Worldview a ensuite subi un traitement Pansharpening (*Gram-Schmidt*) permettant de combiner l'image panchromatique à 50cm de résolution avec l'image multi spectrale à 2m de résolution afin d'obtenir une image multi spectrale à 50cm de résolution (figure 3.2). Ce procédé permet de garder la précision du panchromatique et d'y ajouter la richesse spectrale auparavant disponible à plus faible résolution. Outre un gain visuel non négligeable, l'augmentation de la résolution est majoritairement utile pour la distinction des rangées de cultures hautes telles que les caféiers (apparition du sol des inter-rangs) et la distinction entre arbres au sein d'un couvert. Si la signature spectrale reste similaire, la texture est quant à elle plus complexe, révélant une organisation spatiale en motifs souvent porteuse d'indices pour la discrimination de zones différentes. L'acquisition d'une image Worldview se justifie par la richesse de ses bandes, permettant ici d'obtenir une signature spectrale à 8 valeurs allant du cyan au proche infrarouge. Les images Worldview 2 sont disponibles au prix de 38\$ au km². Dans notre cas, grâce à la compagnie e-GEOS, une réduction de 20% du prix a été opérée, soit un total de 4773\$ pour le multispectral 8 bandes et le panchromatique des 157km² de l'image.



FIGURE 3.2 – Apport du pansharpening pour la distinction d'éléments fins des cultures agraires : exemple de Worldview 2 (couleurs naturelles)

3.1.3 Acquisitions Pléiades

Deux acquisitions Pléiades dites « tristéréo » (acquisitions simultanées, donc sous les mêmes conditions d'illumination, d'une même zone mais avec 3 angles de prise de vue différents) ont été programmées pour Janvier 2015. Les caractéristiques précises des images correspondantes sont présentées en annexe. Ces images ont été livrées sans corrections radiométriques ni géométriques : ces corrections ont été réalisées par la suite durant le stage. L'idée est ici de pouvoir maîtriser la chaîne de traitement et pouvoir éventuellement l'adapter à des besoins particuliers.

A l'aide du projet GEOSUD¹, les images Pléiades ont été acquises avec un tarif préférentiel pour l'unité TETIS, avec un prix hors taxe au km² de 18 euros en tristéréo, ce qui ramène le total à 3366 pour un bundle 3 acquisitions contenant panchromatique et multispectral 4 bandes.

1. <http://geosud.teledetection.fr/>

3.2 Données issues des campagnes terrain

Plusieurs campagnes de terrain ont été réalisées sur la région de *Murang'a*. Cependant, toutes n'étaient pas pertinentes pour notre travail. On s'intéressera principalement à la campagne de terrain synchrone avec acquisition de l'image WorldView2 ayant permis de repérer environ 2000 petites zones (correspondant principalement à des parcelles agricoles) et de les digitaliser pour être consultées sur un Système d'information Géographique (SIG). Cette vérité terrain a pu alors être remobilisée, après transformations, pour servir de base d'apprentissage aux algorithmes de classification. Par ailleurs, une campagne terrain a été réalisée durant l'été 2015, dont les objectifs étaient :

- De mesurer les hauteurs de caféiers sur plusieurs parcelles (ainsi que d'autres informations) afin d'évaluer la capacité des produits stéréoscopiques à séparer les parcelles de caféiers en classes de hauteur
- De mesurer la hauteur d'arbres isolés afin d'évaluer la précision de ces mêmes produits pour les arbres

3.3 Méthodologie globale

La méthodologie est portée vers l'expérimentation de nouvelles méthodes mais reste ancrée dans un schéma de production aboutissant à la production d'une carte de classification. Nous nous sommes efforcés d'allouer les phases d'expérimentation de manière à ce que du temps puisse être pleinement consacré à mener à bien la création d'une carte de classification et les interprétations sur les résultats. La figure 3.3 se lit ainsi temporellement de haut en bas et illustre la conduite de plusieurs tâches en parallèle.

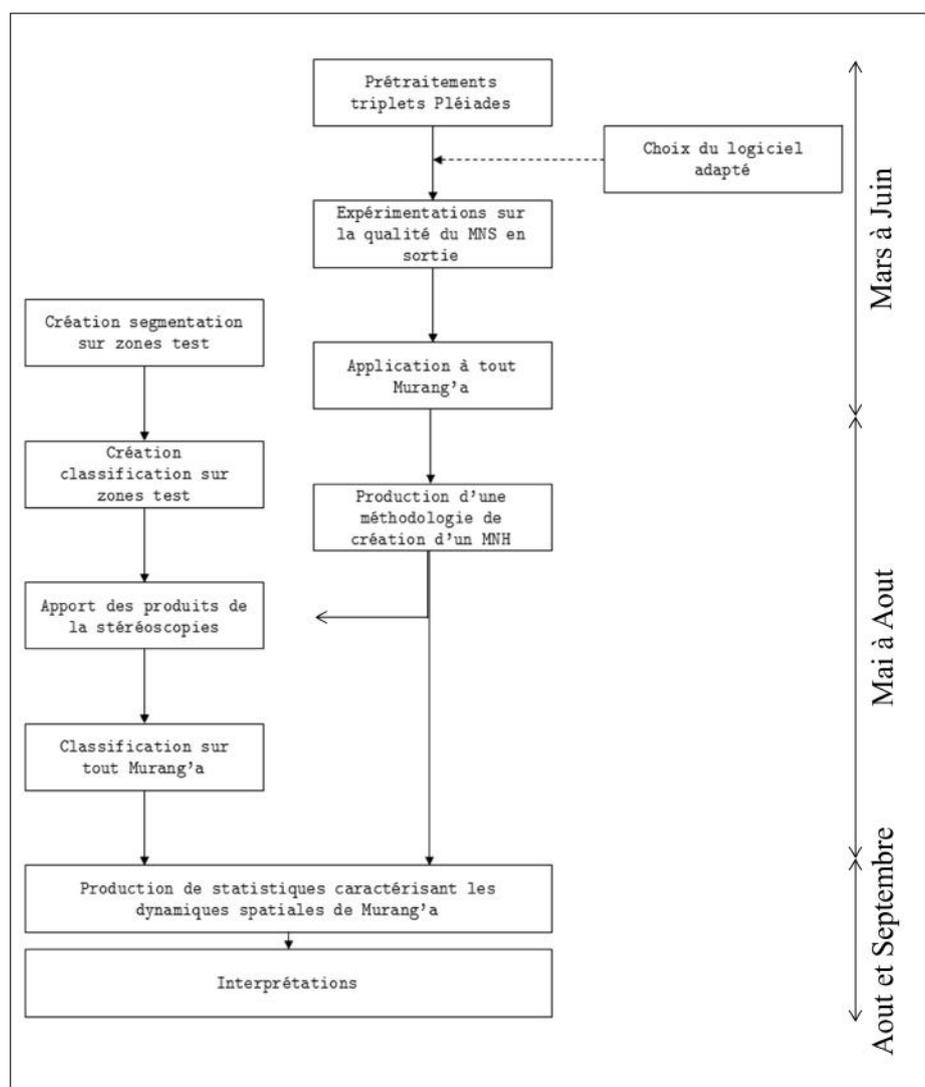


FIGURE 3.3 – Méthodologie et chronologie du stage

3.4 Moyens logiciels à disposition durant la mission

L'intégration à l'équipe de l'UMR TETIS a permis l'accès à de nombreux logiciels payants spécialisés dans le traitement d'images satellite. On citera ainsi ArcGIS (toolboxes incluses), ENVI, Ecognition et ERDAS Imagine dont certaines fonctionnalités furent essentielles pour la progression. Cependant, il fut préféré, lorsque cela était possible, l'utilisation de logiciels libres et gratuits aux logiciels payants, en privilégiant par exemple QGIS à ArcGIS. Le choix est motivé par les perspectives d'applications que l'on entrevoit après l'étape de recherche. Plus la charge en logiciels payants est importante, plus le cercle d'institutions pouvant potentiellement utiliser la méthode se restreint. Une vue plus détaillée des logiciels mobilisés pour les traitements est présentée en annexe A.

4.1 Définition du principe de la stéréoscopie et état de l'art des applications par satellite

Par définition, une photographie constitue une projection sur une surface d'une réalité tridimensionnelle. La stéréoscopie peut être définie comme l'art de reproduire une perception du relief à partir d'images, donc de matrices 2D. L'exemple d'utilisation le plus connu est celui de la vision stéréoscopique répandue dans le règne animal, permettant de mieux percevoir les distances à partir de 2 (ou plus) yeux interprétant la même scène sous des angles différents. L'effet de relief obtenu est ainsi produit par la parallaxe, c'est-à-dire l'effet du changement de position sur l'image perçue.

Aujourd'hui, l'acquisition et le traitement d'images numériques sont devenus plus aisés et moins coûteux, la stéréoscopie s'est imposée comme un moyen intéressant pour la production de données 3D à coût raisonnable. Ses applications sont variées et couvrent des domaines tels que l'architecture, le médical ou le divertissement, dont les enjeux économiques furent cruciaux au développement des connaissances théoriques et applicatives qui y sont liées. Si les principes généraux de la stéréoscopie et de la photogrammétrie ne sont plus considérés comme une question de recherche, son application dans certains cas particuliers pose encore des questions fondamentales qu'il convient d'examiner.

C'est le cas de la stéréoscopie par satellite. Utilisée depuis les années 80, elle permet de modéliser la surface terrestre par le biais d'images acquises en orbite par des satellites d'observation de la Terre. Les 30 dernières années ont ainsi vu l'émergence de deux types de produits issus de la stéréoscopie par satellites, les MNT offrant une estimation du relief sans le sursol et les MNS offrant une estimation de tout le relief.

Techniquement, il est possible de réaliser un traitement stéréoscopique avec plus de 2 images acquises avec un angle de visée différent. On parle alors de tri-stéréoscopie lorsque 3 images sont utilisées. Les couples d'images possibles sont alors traités l'un après l'autre puis les résultats sont fusionnés. La tri-stéréoscopie trouve essentiellement son intérêt dans la cartographie de zones à la topographie contrainte, la multiplication des points de vue permettant alors de réduire les zones d'occlusion non « vues » par une paire stéréoscopique classique.

Etant donné la complexité des systèmes agroforestiers, la caractérisation de leur structure 3D peut apporter un éclairage nouveau sur les informations accessibles par télédétection. (Russell and Sanz, 2012) réalise un état de l'art de ces différentes techniques pour une utilisation agricole, au coût et à la précision variables. On retrouve parmi ces techniques la stéréovision, mais son utilisation sur des images satellite n'est pas mentionnée. De manière générale, malgré la généralisation de l'utilisation d'images satellites pour l'agriculture, y compris à THRS, la branche stéréoscopique reste encore peu utilisée.

Historiquement, on retrouve dans les années 80 des exemples d'utilisation d'images satellite acquises sous deux angles différents (Cooper et al., 1987; Simard, 1987). Ces avancées sont notamment permises par les progrès importants en termes d'appariement d'images (Gruen, 1985). On peut alors passer d'une donnée planimétrique à une donnée altimétrique, mais uniquement pour la production d'un MNS sans distinction possible du sursol compte tenu de la résolution des images utilisées.

Les avancées importantes en termes d'appariement (Lowe, 2004), de photogrammétrie et d'imagerie satellite ont ouvert par la suite la porte à la production de MNT et de MNH dont on peut comparer la précision avec des modèles issus d'une acquisition LiDAR. Les techniques de traitement, héritées de la photogrammétrie, continuent encore d'évoluer pour prendre en compte les spécificités de la prise de vue par satellite, notamment des capteurs à barrettes (Wang et al., 2011). On distingue alors des applications urbaines et des applications environnementales. Les applications urbaines furent les premières à émerger en raison des enjeux autour de l'urbanisme et de la relative simplicité géométrique des milieux urbains (Toutin, 2004). Quant aux applications environnementales, on retrouve principalement des exemples d'utilisation pour la mesure des hauteurs de forêt (comme indicateur d'estimation de la biomasse par exemple)(Ni et al., 2015).

On ne retrouve cependant pas d'études visant à estimer la reconnaissance d'arbres individuels. De la même manière, la reconnaissance de cultures « hautes », parce que de type arboré telles que les caféiers, cacaoyers ou autres fruitiers, n'a pas été abordée; la bibliographie en application aux problématiques agricole est inexistante.

De manière générale il est très vite mis en évidence que les deux facteurs influant sur la qualité d'un traitement stéréoscopique sont d'une part l'imagerie utilisée en entrée (nature du capteur, nombre d'images, angle entre images) et l'algorithmique utilisé, dont le paramétrage doit souvent tenir compte du premier facteur. On trouve des exemples d'utilisation de la tri-stéréoscopie (2 couples d'images de la même scène) (Greugny, 2014; Poli et al., 2014), mais l'accent n'est pas mis sur la comparaison avec un couple seul. (Durand et al., 2013; Greugny, 2014) examinent plus particulièrement le traitement d'images Pléiades par différents logiciels propriétaires ou libres. Les résultats de ces benchmark ne sont cependant pas absolus étant donné le fort paramétrage des logiciels qui reste un problème rapidement insoluble au vu du nombre de paramètres à considérer. Ils ne tiennent de même pas compte de l'apparition de solutions émergentes innovantes tels que le pipeline s2p (De Franchis et al., 2013).

L'influence de la précision de l'ortho rectification sur la qualité du produit est abordée dans certaines études, en faisant varier le nombre de Ground Control Point (GCP) voire en les supprimant (Toutin et al., 2012), mais il n'existe pas d'étude globale. D'autres études proposent des méthodes pour le calage précis des couples d'image stéréoscopiques (Tong et al., 2010). La question de l'efficacité des descripteurs locaux usuels implémentés dans des algorithmes tels que SIFT et SURF est cependant posée. D'autres études se fixent sur un algorithme et font varier la source, donc le satellite utilisé. Là encore il est souligné que le choix de l'algorithme n'est pas anodin et qu'il pourrait favoriser l'une des solutions.

Il existe un autre facteur limitant dans les chaînes de traitement stéréoscopique haute précision, celui de l'isolement du sursol par rapport au terrain. De la même manière que pour le LiDAR, une des pistes consiste à travailler sur un nuage de point pour détecter les fortes variations de pentes et classifier les points au-dessus du sol avant de les supprimer. Il sera ainsi possible de créer une carte de sursol non influencée par le terrain. Cette technique est cependant moins efficace sur les nuages de points issus de la stéréoscopie satellite, la densité étant moins importante et les pentes adoucies par rapport à un nuage LiDAR. Des alternatives existent consistant à travailler directement sur le MNS (Perko et al., 2015) ou à conduire une classification en amont du sursol sur l'image (Dehvari and Heck, 2012).

La question du nombre d'images pour la stéréo et des angles d'acquisition est abordée sur la production de MNT via Cartosat en zone de forte pente(Giribabu et al., 2013).

En résumé, de plus en plus d'études utilisant la tri-stéréoscopie apparaissent, elles vont de pair avec la communication des fournisseurs d'images qui mettent de plus en plus en valeur ces

produits et proposent des offres en bundle. Les traitements stéréoscopiques restent cependant compliqués et nécessitent une bonne maîtrise des logiciels dédiés ainsi que leur achat dans certains cas.

4.2 Etat de l'art des solutions logicielles actuelles

Au-delà de la provenance de l'image, le développement de la stéréoscopie a débouché sur une large gamme d'offres pour les professionnels souhaitant exploiter leurs résultats pour des travaux de recherche ou des applications concrètes. On séparera ici les offres proposées en termes de produits bruts et les offres en termes de solution logicielles de traitement des données pour ne garder que ces derniers. Les résultats obtenus proviennent des informations glanées sur les différentes solutions ainsi que sur le rapport de Valentin Greugny interne à la Maison de la Télédétection (Greugny, 2014). Un benchmark complet des différentes solutions est hors de la portée de ce rapport, un rapide résumé est cependant là pour replacer l'offre dans le contexte et justifier le choix réalisé pour une question de recherche.

TABLE 4.1 – Etat de l'art des différentes offres logicielles permettant le traitement d'images stéréoscopiques satellite

Logiciel	Licence	Prix	Spécialisation	Utilisation	Paramétrage
<i>Micmac</i>	Libre	Grat.	Général	Commandes	Très élevé
<i>VisualSFM</i>	Libre	Grat.	Général	Interface	Non exploré
<i>ASP(NASA)</i>	Libre	Grat.	Satellite	Commandes	Non exploré
<i>Orfeo ToolBox (OTB)</i>	Libre	Grat.	Satellite	Commandes	Très élevé
<i>S2P</i>	Libre	Grat.	Pleiades	Web	Faible. Limitations
<i>ERDAS LPS</i>	Prop.	Pay.	Aérien	Interface	Profond
<i>PCI Geomatics</i>	Prop.	Pay.	Aérien	Interface	Non exploré
<i>APS suite</i>	Prop.	Pay.	Aérien	Interface	Non exploré
<i>Agisoft</i>	Prop.	Pay.	Aérien	Interface	Non exploré

On retient qu'il existe quatre niveaux de spécialisation :

- **Photogrammétrie générale** : correspond aux logiciels pensés pour tout problème de photogrammétrie, pouvant inclure les acquisitions aériennes ou les acquisitions à 360° d'un bâtiment ou un objet au sol.
- **Photogrammétrie aérienne** : correspond aux logiciels dont les capacités et l'ergonomie sont pensées pour le traitement d'images aériennes, le plus souvent issues de drones. Les images satellite peuvent être traitées, soit par des modules rajoutés, soit en renseignant soi-même l'orientation interne (prise en compte des caractéristiques du capteur comme la focale et les déformations) et l'orientation externe (positions relatives de l'objectif au moment des prises de vue).
- **Stéréo satellite** : correspond aux logiciels adressant tout particulièrement les problèmes liés à la stéréoscopie par satellite. Ces logiciels supportent une liste de capteurs définie.
- **Stéréo Pleiades** : correspond à une solution exclusivement dédiée au traitement d'images Pleiades stéréoscopiques.

La dernière solution est idéale car elle réduirait le temps passé à paramétrer le logiciel. La seule solution proposant cela dans notre étude est cependant une solution Web limitée en capacité de traitement. Le logiciel idéal selon la tâche prendrait en compte la totalité de la chaîne mais permettrait beaucoup de flexibilité et un output à chaque étape pouvant être repris facilement par des logiciels annexes.

La diversité des produits et celle des logiciels est réelle. Il convient de choisir l'offre adaptée en fonction des objectifs recherchés, du budget consacré et des compétences à disposition. Dans notre cas, nous avons décidé de suivre les recommandations dictées dans (Greugny, 2014) et d'utiliser ERDAS Imagine pour les traitements stéréoscopiques. Cependant, nous avons aussi souhaité compléter la démarche par des tests sur l'OTB se distinguant par une philosophie d'utilisation très différente du logiciel d'ERDAS. Les tests furent abandonnés en raison des nombreux problèmes techniques rencontrés mais se sont montrés prometteurs quant à l'utilisation de logiciels Open Source pour des tâches de stéréophotogrammétrie complexes. Le logiciel Micmac aurait quant à lui pu être utilisé mais la conversion des méta données Pléiades en orientation interne compréhensible par Micmac est complexe, bien que réalisée en routine par l'IGN.

4.3 Pré-traitements réalisés sur l'imagerie Pléiades

Les images Pléiades reçues sont au niveau 1 de traitement. Dans la typologie Pléiades, cela signifie qu'il n'y a pas eu de corrections appliquées à l'image d'origine, qu'elles soient radiométriques ou géométriques. Partant d'une image brute, il faudra donc recalculer l'image sur une référence et standardiser les valeurs radiométriques en tenant compte des conditions de prise de vue. La figure 4.1 résume ces étapes préliminaires nécessaires avant de passer à la stéréoscopie.

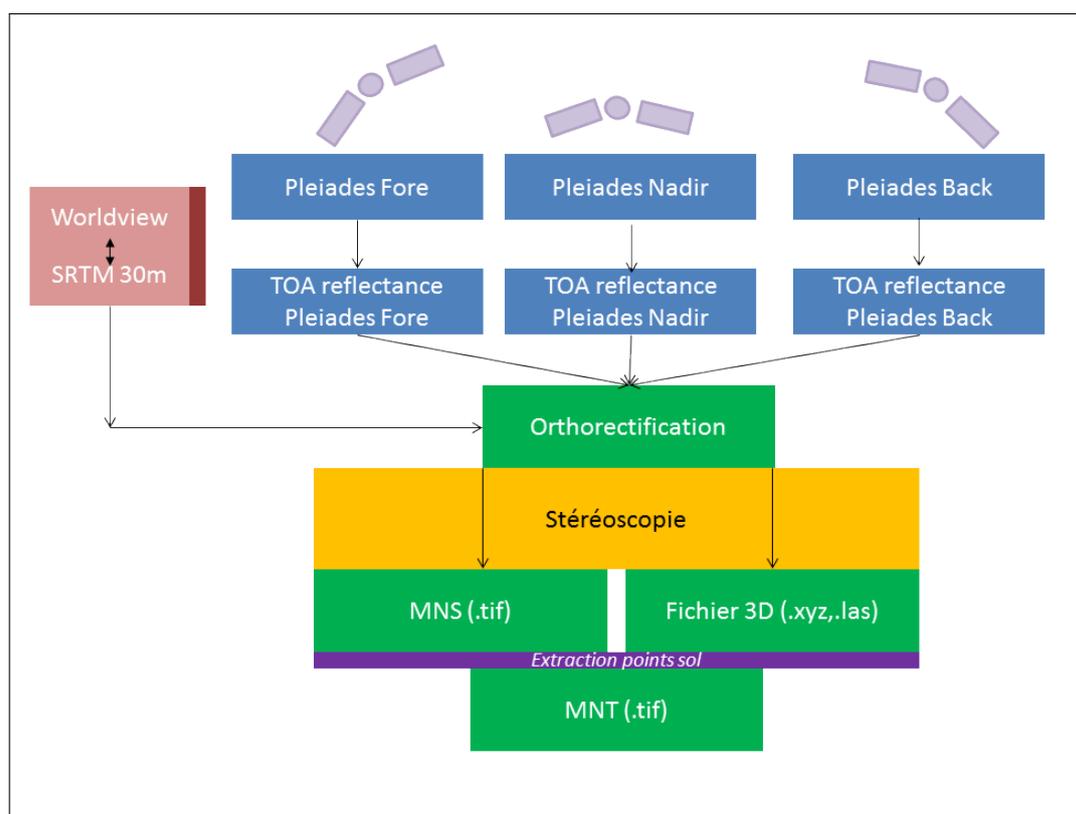


FIGURE 4.1 – Grandes étapes de la chaîne de traitement stéréo

4.3.1 Corrections radiométriques

De manière analogue à un appareil photo, le signal perçu par un satellite est transformé en une matrice de valeurs numériques. Cette valeur appelée Digital Count (DC) n'est pas comparable entre deux prises de vue car les conditions sont différentes. Il est donc nécessaire de corriger ces valeurs numériques en valeurs de réflectance comparables. Plusieurs niveaux de corrections existent et sont détaillés dans la figure 6.8, le choix du niveau dépendant des métadonnées disponibles. Nous faisons ici le choix d'aller jusqu'à la réflectance Top Of Atmosphere (TOA), car nous ne possédons pas les données atmosphériques permettant d'aller plus loin dans les corrections. Cette étape est essentielle car plus l'angle entre deux acquisitions augmente, plus la réponse radiométrique des objets diffère et nécessite une correction...

4.3.2 Corrections géométriques

La seconde étape de traitement consiste à relier la grille de pixels de l'image à la géographie terrestre (dans le système de coordonnées souhaité). Cette étape de calage est essentielle pour pouvoir superposer par la suite les 3 images stéréo sur l'image de référence. Un bon calage est de même souhaité pour les étapes ultérieures de segmentation et classification si celles-ci font intervenir la fusion de données provenant de sources différentes. Selon le contexte et le degré de précision souhaité, on note deux grands types de corrections géométriques : le géo-référencement simple et l'orthorectification prenant en compte le relief et aboutissant à un raster où chaque pixel est théoriquement vu au nadir. Nous choisissons cette dernière option en raison des contraintes topographiques de la région et de la précision demandée pour les applications stéréo. Dans notre cas, avec 3 images à orthorectifier, il est souhaitable de caler toutes les images en même temps pour améliorer les résultats. On relèvera alors en plus des GCP (point de relation entre l'image à orthorectifier et l'image référence) des points d'ancrage appelés Tie Point (TP) permettant de caler les images de la série stéréoscopique entre elles (coordonnées image contre coordonnées image).

Ces compléments aux GCP peuvent être pointés manuellement mais dans certains cas aussi de manière automatique à l'aide d'algorithmes de détection de points invariants. C'est le cas de SIFT et de SURF, particulièrement appréciés pour leur robustesse face aux changements d'échelle et de rotation (Lowe, 2004). Ces algorithmes établissent une liste de points dits invariants pour chaque image puis relient les points invariants entre eux selon deux critères, la similitude entre les divers indicateurs calculés sur les points et la cohérence géométrique par rapport aux associations déjà réalisées. Ces algorithmes sont cependant fortement sensibles aux variations d'angle de vue et de luminosité, il n'a ainsi pas été possible dans notre étude de relier deux images Pléiades à -8° et 12° d'incidence, là où l'association entre celles à -8° et -16° s'est déroulée avec succès. Il a donc fallu pointer manuellement ces points. En cas de succès dans l'appariement, une étape postérieure de contrôle des points est nécessaire pour éliminer certains couples de points erronés, elle peut être réalisée en filtrant les points avec une forte erreur résiduelle ou en supprimant manuellement les points que l'on juge mauvais.

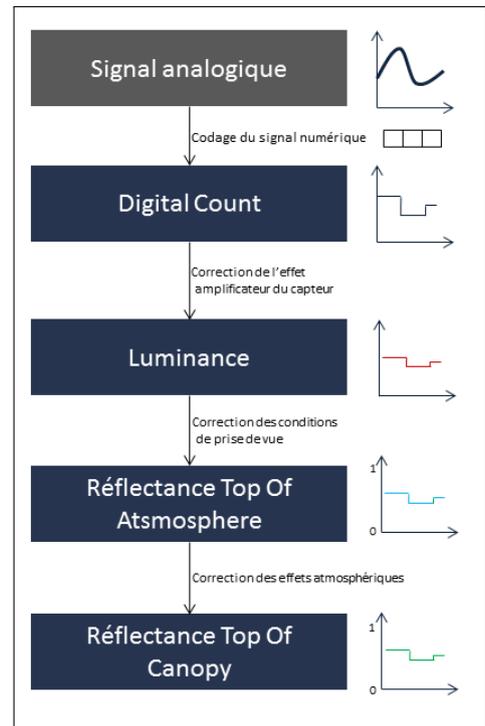


FIGURE 4.2 – Étapes de correction radiométrique des images Pléiades

L'ortho-rectification est une étape cruciale au processus de stéréoscopie car de la qualité de superposition entre les images de la série dépend la qualité des associations qui seront faites entre un même objet vu sous plusieurs angles. Le nombre de GCP à utiliser pour un bon résultat est difficile à déterminer. Ici, nous avons décidé de couvrir la surface de 101 points de contrôle. De cette manière, la plupart des pixels de l'image sont situés à moins de 3km du GCP le plus proche comme le montre l'annexe F. Il paraît donc nécessaire d'évaluer après-coup la qualité de cette ortho rectification. On décide de calculer l'erreur lorsque l'on n'utilise pas de GCP et l'erreur lorsque l'on utilise des GCP. Dans les deux cas, on calculera deux types d'erreurs :

- L'erreur moyenne INTER, c'est-à-dire la qualité du calage par rapport à l'image de référence (Worldview 2), c'est l'écart relatif entre les images sur une moyenne de plusieurs points répartis équitablement au sein de la zone. Cet indicatif nous donne la précision géométrique moyenne des produits, il est important pour assurer la future superposition du MNS avec l'image de référence ou d'autres sources géoréférencées.
- L'erreur moyenne INTRA, c'est à dire l'écart moyen entre les 3 images ortho rectifiées. Cet indicatif sera crucial pour assurer la bonne mise en œuvre du pipeline de stéréoscopie et donc la qualité des données du MNS par rapport à ce que serait un MNS parfait de la zone.

Les résultats sont présentés dans les deux graphiques suivants :

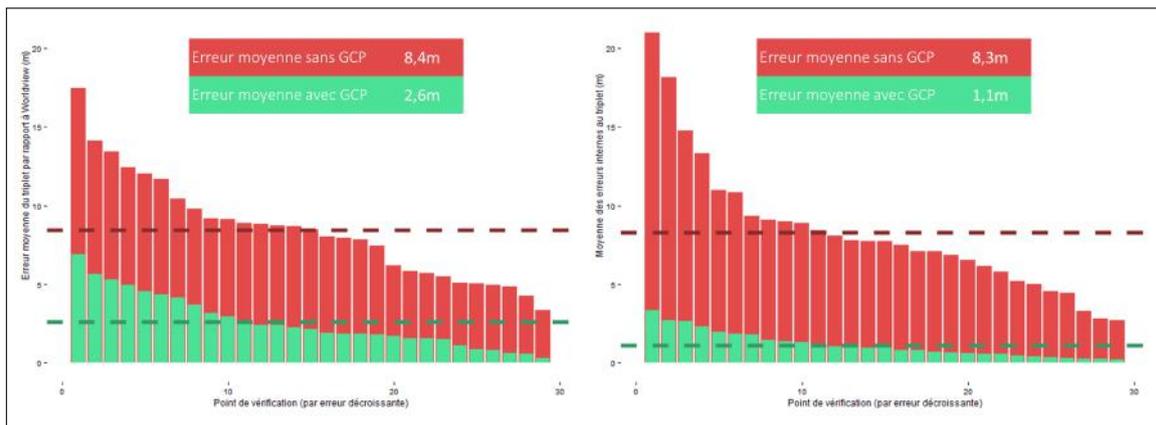


FIGURE 4.3 – Erreurs décroissantes sur un jeu de points de vérification
Gauche : Erreur Pléiades/Worldview
Droite : Erreur Pléiades/Pléiades

La précision du calage dépend de la zone mais il est possible d'assurer en moyenne une erreur métrique sur le calage entre images Pléiades. On remarque que l'utilisation des GCP est beaucoup plus efficace pour caler les triplets d'images entre eux que pour caler le triplet avec l'image de référence. L'explication la plus plausible est d'avancer que cela est du aux différences importantes entre images Pléiades et images Worldview, différences qui ne facilitent pas la recherche de points parfaitement identiques entre elles.

Il est nécessaire de considérer aussi l'erreur admise lors de l'orthorectification de l'image Worldview 2 (considérée comme référence) avec un SRTM précis à 30m (meilleure source de données disponible). Une ortho rectification par des points de contrôle pris au GPS pourrait être plus précise ; des relevés terrain existent mais leur localisation précise sur l'image est trop vague. Nous décidons donc de ne pas en utiliser.

4.4 Traitement stéréoscopique des données sous ERDAS IMAGINE, solution propriétaire, payante et paramétrable

Une fois que les données ont été calées entre elles, celles-ci peuvent être intégrées dans les modules photogrammétriques du logiciel ERDAS IMAGINE : LPS et ATE. En plus de l'orthorectification des données, LPS intègre l'import des métadonnées de l'acquisition afin de reconstituer l'orientation externe et l'orientation interne. Toutes ces données sont ensuite transmises au module ATE (ou plus précisément eATE) dont le travail va être de calculer la profondeur en mettant en correspondance toutes les paires possibles d'images. Pour chaque paire d'image, un MNS sera généré ainsi qu'un nuage de points (typiquement au format LAS), les MNS sont ensuite fusionnés par le logiciel pour obtenir le rendu final.

Une zone test a été délimitée, afin de faciliter les calculs, sa taille a été fixée à environ 1km².

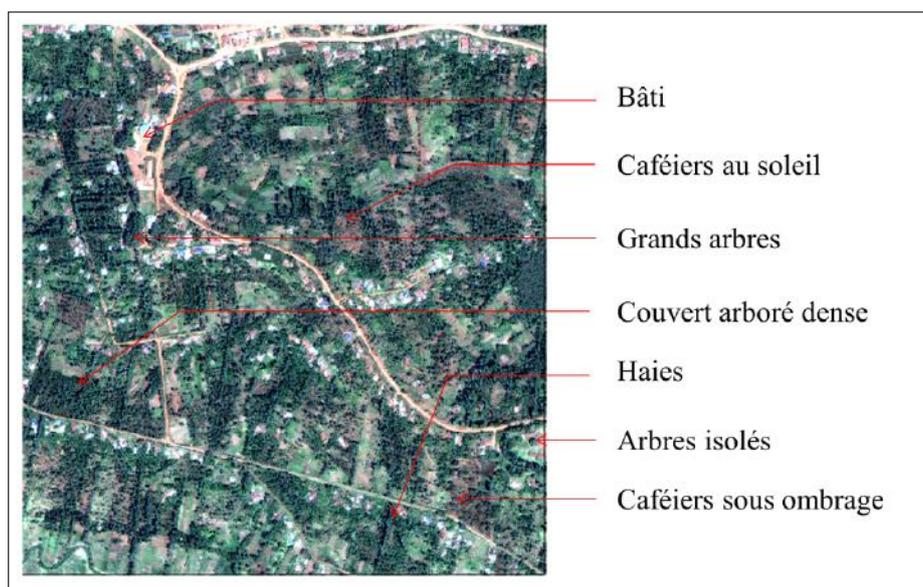


FIGURE 4.4 – Zone de 1km² utilisée pour les tests de stéréoscopie.
Image Pléiades Pansharpening couleurs naturelles

La zone comprend une grande variété de reliefs et de types de sols différents. Cette zone est couverte par les deux triplets Pléiades, il y est par conséquent possible de réaliser de la stéréoscopie sur 6 images. Le choix de cette zone dépend de même des éléments de sol, ici suffisamment variés pour être représentatifs de la complexité de la région. Sur cette mini-zone, quatre grands types d'expérimentations ont été réalisés afin de comprendre ce qui détermine la qualité du MNS :

- Le module eATE étant extrêmement paramétrable, certains paramètres du module ont fait l'objet de variations
- Les MNS produits par toutes les paires possibles avec les six images ont été générés afin de déterminer la meilleure paire
- Les MNS issus de la stéréoscopie à 3 images (tri-stéréoscopie), 4 images, 5 images et 6 images ont été générés afin de voir si l'accumulation de prises de vue est bénéfique
- La pertinence de la stéréo sur des images multi spectrales à 2m de résolution a été testée

Etant donné qu'il n'existe pas d'acquisition LIDAR couvrant la zone, il ne fut pas possible de comparer les résultats avec une donnée de référence. Nous détaillerons ici l'étude sur les différentes paires stéréo. Les autres études sont présentes en annexe H.

4.4.1 Influence de la différence angulaire sur la qualité du MNS

Avec 6 images différentes, il existe 15 paires possibles en ne comptant pas les répétitions. Chacune de ces paires peut être définie par une différence angulaire, c'est-à-dire la différence entre les deux angles de prises de vue. Celles-ci s'échelonnent ici entre 4° et 30° . On peut alors classer les paires possibles selon leur différence angulaire. Un MNS est alors généré pour chacune de ces paires, sans considérer les autres images. La figure 4.5 illustre les résultats sur un extrait de 250m^2 .

On remarque que plus la différence angulaire est importante, plus la qualité du MNS créé semble diminuer. Nous pouvons formuler l'hypothèse que cela vient de la difficulté à caler précisément les images et que donc les paires avec une forte différence angulaire auront des objets bien plus difficiles à associer.

S'il fallait préconiser un mode opératoire pour la stéréoscopie simple, il semblerait prudent d'acquérir des images prises avec des angles assez proches, avec environ 5° de différence entre chaque image. Cependant il convient de nuancer en rappelant que ces observations ne sont pas forcément universelles.

D'autres tests sont conduits en annexe, examinant la sensibilité aux paramètres du logiciel et l'apport de la tri-stéréoscopie pour la qualité du produit. Les paramètres les plus concluants ont alors été sélectionnés par la suite pour réaliser le MNS. On ne prendra ici en compte que le premier triplet Pléiades car l'utilisation de 6 images pour la stéréoscopie ne semble pas améliorer significativement le rendu et surtout il n'est pas a priori financièrement intéressant d'acquérir 6 images Pléiades pour ces traitements.

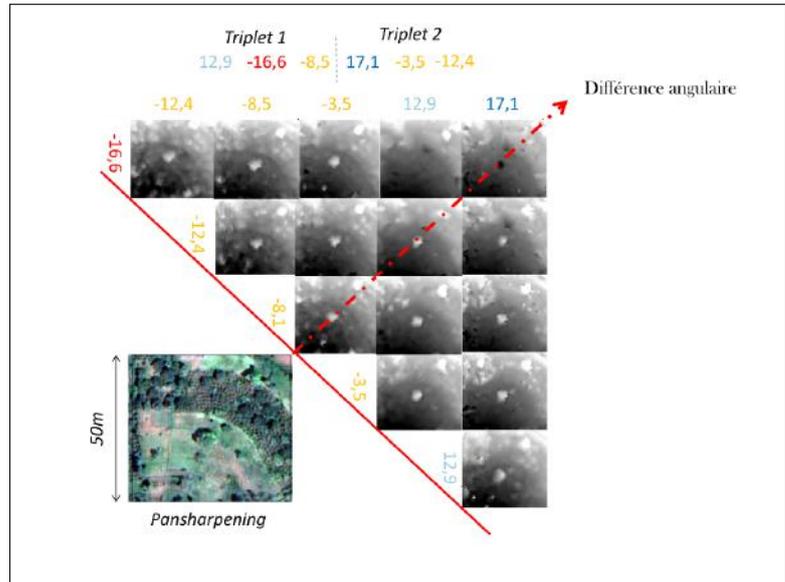


FIGURE 4.5 – Différentes combinaisons de duos stéréoscopiques appliquées à une zone de 50m de côté

4.4.2 Résolution du MNS en sortie

Le choix de la résolution du MNS est une des questions méthodologiques fondamentale à laquelle il est dur d'apporter une réponse. Les attentes pour le MNS sont :

- de retrouver sur le MNS les grandes structures présentes sur le nuage de point 3D sans les éliminer
- de ne pas conserver les aspérités du nuage apportant un bruit

Ce choix est cependant conditionné par de nombreuses contraintes. Au premier abord, il serait naturel fixer une résolution correspondant à la densité moyenne de points. Mais dans la réalité, la répartition des points est trop hétérogène pour pouvoir appliquer cette règle.

L'image Pléiades en entrée a une résolution de 50cm mais cela ne veut pas dire que le MNS en sortie est apte à différencier des objets de l'ordre du demi-mètre. Le MNS en sortie provient de l'interpolation du nuage de point. Cela représente une difficulté car la densité du nuage de point n'est pas constante. De manière générale, la densité moyenne en points n'est pas suffisante pour être informative dans un MNS à 50cm. Nous avons décidé de tester différentes résolutions pour le MNS et de regarder à partir de quelle résolution nous n'observons plus une

augmentation de la qualité du produit. Au vu de ces observations, il fut décidé de se fixer sur un MNS à 1m de résolution, mais d'autres choix comme un MNS à 2m auraient pu aussi se justifier, la différence ayant poussé à choisir 1m étant le gain de netteté qui en résulte.

4.4.3 Observations sur le MNS créé

Observons dans la figure 4.6 l'image ainsi obtenue sur la zone test. Pour plus de clarté, on décide de la combiner avec une transformation de l'altitude en relief. Cette transformation est faite grâce aux fonctionnalités « Analyse de terrain » présentes sous QGIS. Le résultat permet de faire ressortir à la fois la topographie et le sursol, sans que l'un n'empêche la visualisation de l'autre.

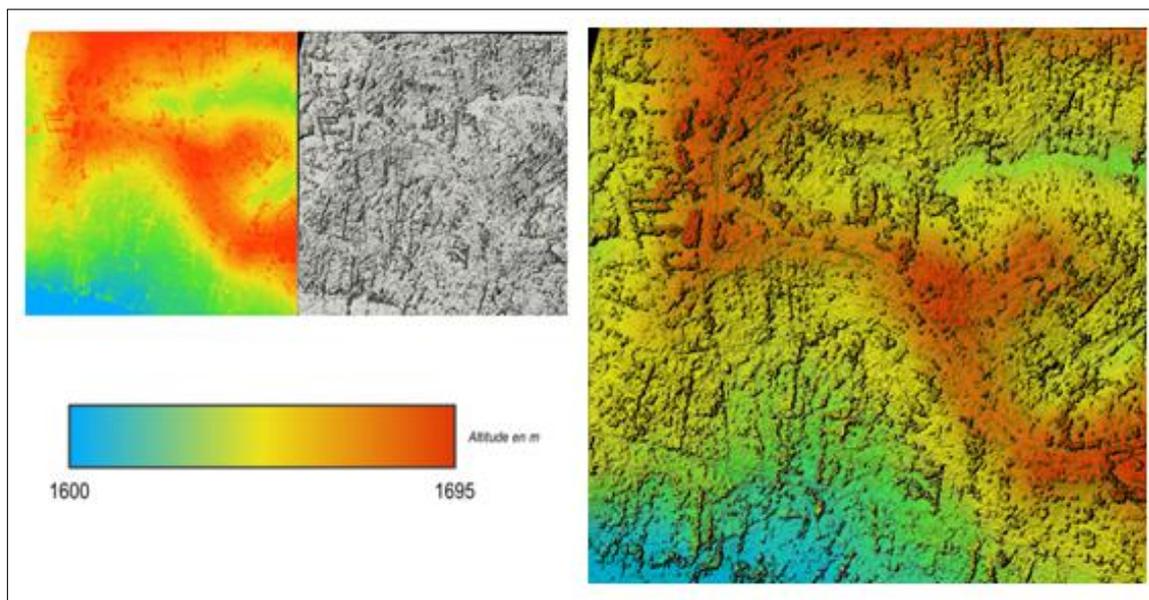


FIGURE 4.6 – Modèle numérique tri-stéréo obtenu avec les réglages de base
Gauche : MNS brut et en relief
Droite : Combinaison des deux

Par rapport à la réalité, on remarque une tendance du MNS stéréoscopique à « arrondir » les transitions entre les différents objets qui sont normalement beaucoup plus nettes, notamment dans le cas des bâtiments. On retrouve les bâtiments et les arbres différenciés de manière assez claire. Cependant les cultures de petite taille telles que les caféiers ne semblent pas reconnues, ou du moins n'apparaissent pas distinctement à l'œil.

4.4.4 Application à la zone entière

Nous avons obtenu un paramétrage satisfaisant pour le traitement sur une zone type, ce même traitement est ensuite appliqué sur la zone entière. L'opération ne pose pas de problème, à la subtilité près qu'il a été nécessaire de diviser la zone en 5 parties (avec des bandes communes pour le raccord) afin de limiter le risque de plantages du logiciels. En dehors des bords de l'image à la qualité moindre, il ne semble pas y avoir de défauts liés à l'application sur toute la zone.

4.5 Transformation du MNS en MNH

Le MNS obtenu apporte seulement une information d'élévation globale : Il renseigne en bloc sur la hauteur des objets au-dessus du sol associée à l'altitude. Afin de ne conserver que

la hauteur du sursol, il est nécessaire de retrancher au MNS l'altitude du sol en tout point, c'est-à-dire le MNT. En l'absence d'un MNT acquis directement, à la même résolution que le MNS (pour rappel le MNT SRTM est à 30m/pixel), l'opération n'est pas simple car elle revient à déterminer quels éléments sur le MNS appartiennent au sursol. Dans le cas des MNS créés à partir d'images satellites, il est de plus très difficile de déterminer le sursol en raison des ruptures de pente assez peu marquées. Deux méthodes sont alors retenues :

- La méthode consistant à segmenter puis classifier le MNS afin de déterminer les objets appartenant au sursol
- La méthode consistant à détecter les points de sursol directement sur le nuage de points, cette méthode est très répandue pour le traitement de nuages de points LiDAR.

Dans les deux cas l'idée est de détecter les valeurs importantes de pentes trahissant le sursol. La différence étant que dans un cas on travaille sur des points et dans l'autre sur des objets. Le détail de ces 2 techniques est présenté en annexe. Une autre approche non abordée ici consisterait à utiliser l'information spectrale pour classifier le sol et réutiliser cette information comme un masque à apposer sur le MNS.

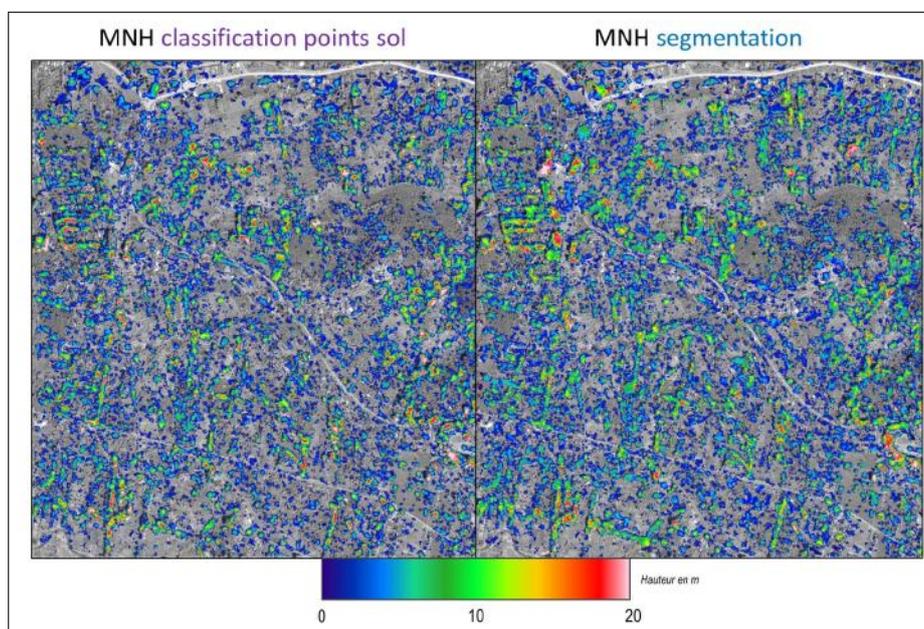


FIGURE 4.7 – Comparaison du MNH extrait par deux méthodes différentes

L'extraction optimale est cependant impossible. Il existe en effet deux contraintes à cela, la contrainte topographique (fortes pentes) et la contrainte des données, les contours des objets du sursol n'apparaissent souvent pas nettement. Par conséquent, il arrive que la pente mesurée durant la transition sol/sursol soit moins marquée que la pente naturelle, le sursol ne sera donc pas détecté. En l'état, la méthode est de même imparfaite pour les zones de sursol couvrant une grande surface sans discontinuité (couvert forestier continu par exemple). La méthode "segmentation" sera retenue car elle semble retenir "oublier" moins d'éléments du sursol.

4.6 Vérification de la précision en hauteur des données terrain

Nous nous proposons d'évaluer la précision du MNS à partir de sa capacité à restituer des valeurs réelles de hauteur, notamment sur les arbres. La tâche est difficile car le MNS de

base ne nous donne pas une estimation de la hauteur de l'arbre, simplement de l'élévation de l'arbre (altitude + hauteur). Au vu des données et des méthodes que l'on a déjà mobilisées, nous pouvons imaginer 4 méthodes différentes (détaillées en annexe) permettant d'obtenir la hauteur d'arbres présents sur le MNS :

- Utiliser directement le MNH précédemment créé (H_MNH)
- Soustraire au MNS le MNT SRTM 30m (H_METHOD_SRTM)
- Soustraire au MNS le MNT SRTM 30m interpolé à 1m par krigeage ($H_METHOD_SRTM_KRIG$)
- Soustraire au MNS l'altitude moyenne de 4 points choisis manuellement autour de chaque arbre (H_METHOD_man)

Un échantillon de 29 arbres, répartis près de sites de précédentes enquêtes dans la région, a donc été mesuré sur le terrain au moyen d'un dendromètre Vertex qui permet une estimation des hauteurs d'arbres avec environ 50cm de précision : leur hauteur varie de 9,5 mètres à 30,9 mètres, avec un écart type de 5,7 mètres.

On retrouve dans l'échantillon 9 espèces d'arbres différentes dont la plus représentée est le Grevillea. L'analyse statistique des résultats est réalisée à l'aide du langage R.

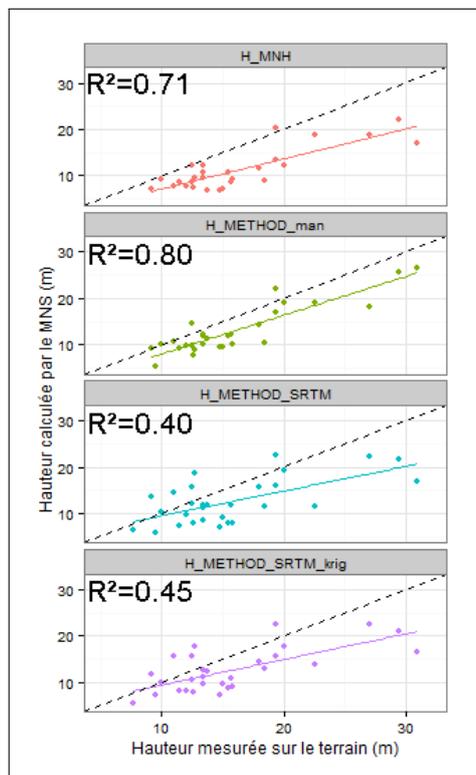


FIGURE 4.8 – Régression linéaire entre données terrain et données MNH extraites selon 4 méthodes différentes

permet cependant de rehausser un peu la valeur du R^2 .

Ces résultats prouvent dans le cas de Murang'a qu'il est possible de se fier directement aux mesures du MNH pour assigner des classes de hauteur à une grande quantité d'arbres.

Il est intéressant de noter que sur la totalité des arbres sondés sur le terrain, certains n'ont pas été retrouvés sur le MNS. Les facteurs pouvant déclencher une non apparition d'un arbre sur le MNS sont généralement sa taille (les petits arbres sont mal reconnus) et l'environnement qui l'entoure (manque de contraste mettant mal en évidence l'arbre). Ces arbres, en grande partie des arbres non isolés au sein des parcelles, ont été éliminés des régressions.

Les hauteurs mesurées sur le terrain et estimées avec le modèle numérique sont bien corrélées mais avec en général une sous-estimation par le MNS. Il est difficile de trouver une explication à ce phénomène, qui n'est pas gênant du moment qu'il est connu et qu'il n'empêche pas d'associer les arbres à plusieurs classes de hauteur. Si une estimation précise de la hauteur ne semble donc pas raisonnable, il est au moins possible à l'aide de cette technique de séparer les arbres en classes de hauteur avec une bonne confiance.

Toutes les méthodes ne donnent cependant pas des résultats similaires. La méthode manuelle est sans surprise la plus adaptée avec un R^2 d'environ 0,8, talonnée de près par la mesure automatique sur le MNH. Les méthodes utilisant le MNT SRTM ont de leur côté du mal à faire apparaître une régression claire, l'interpolation du MNT

La première partie de ce travail nous a conduits à explorer les possibilités qu'offrait la photo stéréoscopie sur images satellites. Les produits obtenus sont à remettre dans le contexte du projet, dont le but est d'établir une carte d'occupation des sols sur la région afin de faciliter les interprétations concernant l'organisation spatiale de la zone. Le MNH créé devrait constituer un indicateur précieux pour distinguer les zones de végétation possédant une structure verticale particulière. L'objectif est ici de relater la méthodologie adoptée pour réaliser la classification sur les produits issus de Pléiades principalement mais aussi de Worldview 2.

Dans un premier temps, nous établiront une liste des classes que nous souhaitons voir représentées dans la classification. Puis nous justifierons les choix algorithmiques qui ont été adoptés pour mener à bien la classification. Les résultats pour diverses stratégies de classification seront ensuite présentés et expliqués avant de terminer par l'application de la meilleure stratégie à la région entière.

5.1 Séparation de l'espace en classes thématiques

On définit une classe thématique comme un libellé thématique associé à un ensemble de zones de la région. Elle est thématique car elle dépend de l'objectif recherché et donc du degré de précision voulu pour caractériser des ensembles plus ou moins similaires. Nous n'avons dans notre cas que très peu d'intérêt à caractériser les routes et le bâti : ce sont les zones de végétation qui nous intéressent le plus, il est donc nécessaire de les discriminer finement. Les types d'occupation du sol sont ainsi dans un premier temps séparées en deux « méga-classes » : les zones de végétation (qu'elles soient naturelles ou agricoles) et les zones de non-végétation (urbain, sol nu, eau). Le sol nu est ici un cas particulier, dans le sens où une parcelle agricole peut aussi occasionnellement contenir seulement du sol nu, selon son cycle cultural. Ces classes, même si elles n'entreront pas dans un premier temps dans l'interprétation de la carte, sont nécessaires dès les premières étapes de classification pour isoler les classes spectrales correspondantes et éviter de potentielles confusions dans les classes spectrales plus végétales. Les différentes classes végétales ont été choisies d'une part en raison de leur capacité à se distinguer les unes des autres, donc à engendrer le moins d'erreurs possible dans la cartographie, mais aussi car elles ont un réel intérêt thématique dans le cadre de l'estimation des proportions respectives des différents systèmes de culture dans la zone et de leur distribution géographique et altitudinale.

Les classes non-végétales sont :

- Les routes goudronnées
- Les pistes et le sol nu
- Le bâti (Toits rouges, toits bleus et toits blancs)

et les classes végétales :

- **Cultures herbacées et napier** [VI]. Cela désigne toutes les cultures annuelles (viver, fourrage...), indispensables à l'alimentation des ménages et aux pratiques d'élevage. Cette classe permettra d'évaluer l'importance de cultures dans la région et leur distribution dans la séquence topographique de Muranga. Il est quasiment impossible de distinguer les différentes formes de cultures (maïs, tubercules, légumes, napier, etc...) à partir de l'image donc de les associer à des classes distinctes. Les cultures vivrières présentent une radiométrie variée mais distincte et surtout une absence de texture.

- **Bananiers**[BAN] D'après les études antérieures, le bananier est très présent dans la zone la plus basse mais sa répartition est encore incertaine même si on sait que les bananes participent à l'alimentation et sont revendues sur les marchés locaux. La texture de cette classe (motif en étoile vu du dessus) la rend particulière mais aussi difficile à caractériser voire parfois à repérer à l'oeil nu.
- **Théiers**[THE] Situés dans la zone haute, le thé est une culture alternative au café auquel il se substitue progressivement. Quantifier et localiser ces plantations est un indicateur intéressant. Les parcelles de thé se distinguent radiométriquement par une couleur verte significative et une quasi absence de texture (aspect lisse)
- **Caféiers exposés au soleil**[CA1] Plantations et patches de taille significative où les caféiers apparaissent en plein soleil. Elles se distinguent principalement par la texture créée par l'alternance de sol et de rangs de caféiers.
- **Caféiers avec ombrage**[CA2] Cette classe correspond aux plantations où il est possible de distinguer nettement les caféiers entre les arbres d'ombrage. Les arbres d'ombrages modifient alors totalement l'information radiométrique et texturale par rapport aux caféières au soleil.
- **Système arboré**[ARB] Les systèmes arborés comprennent les systèmes agroforestiers totalement ou quasi-totalement fermés, y compris les caféières à ombrage trop denses ou trop serré pour y distinguer les caféiers, les plantations de fruitiers, mais aussi les parcelles utilisées pour l'exploitation du bois . Il est malheureusement extrêmement difficile d'effectuer avec certitude la séparation entre ces différentes sous-classes.
- **Plantations d'eucalyptus**[EUC] Les forêts d'eucalyptus ne sont pas incluses dans la classe système arboré en raison de aspect et de leur texture très régulière, très reconnaissable et dinstiguable des autres systèmes arborés.



FIGURE 5.1 – Illustration des classes choisies par des exemples délimités sur l'image Pléiades

5.2 Limitations des données radiométriques de l'image Pléiades pour séparer ces classes

La première tentative pour séparer l'espace en classes est d'utiliser la donnée brute contenue dans l'imagerie Pléiades. Cette donnée se présente sous la forme des bandes, et donc des attributs, suivantes :

- Bleu, Vert, Rouge et Proche infrarouge pour l'image multi spectrale (résolution 2m)
- Panchromatique couvrant l'intégralité du spectre de l'image multi spectrale (résolution 50cm) . Il sera considéré pour les étapes de segmentation mais pas pour celles de classification car il peut être vu comme une moyenne sur les 4 bandes, donc une variable corrélée aux autres.

Lorsqu'elles sont utilisées conjointement, les bandes multi spectrales contiennent une information précieuse pour délimiter les objets du paysage. Elles possèdent cependant des limitations incontournables, indépendamment de la technique utilisée. Si celles-ci se révèlent plutôt efficaces pour distinguer la végétation du reste, elles ne parviennent pas à donner satisfaction pour la séparation des classes agroforestières qui nous intéressent. Cela nous permet d'introduire une autre limitation, celle d'une approche orientée pixel. Un élément du paysage appartenant à une classe thématique contient beaucoup de pixels. Dans le cas d'une image très haute résolution, ces pixels prennent des valeurs très diverses, en raison de la texture et des divers petits éléments que l'on y rencontre. Par exemple dans le cas d'une parcelle de caféiers, on trouvera à la fois des pixels verts portant la signature radiométrique du caféier mais aussi des pixels marrons correspondant au sol nu des inter-rangs. Notre étude vise à distinguer des parcelles dont la radiométrie interne est très riche sur une image Pléiades THRS, l'approche pixel n'est donc pas raisonnable. A la place, une approche objet est adoptée, elle consiste à classer des objets (représentés par un polygone), caractérisés par un jeu d'attributs extraits des couches d'information que l'on possède (le plus souvent la moyenne d'une bande d'un raster sur la zone concernée). L'approche objet est d'autant plus justifiable dans le cas où l'on travaille sur des paysages à la structure complexe dans lesquels les grands ensembles ont une signification plus importante que les petits ensembles ponctuels. Tout particulièrement, ce sont les grands éléments qui nous intéressent pour décrire les parcelles d'agroforesterie.

5.3 Introduction de données complémentaires à la radiométrie Pléiades

Afin de contourner les limitations naturelles de la signature R/G/B/PIR des objets, nous sommes partis à la recherche de nouveaux indices permettant une meilleure différenciation des classes. L'intérêt des données présentées ci-après réside dans leur source commune, à savoir l'imagerie Pléiades. Cela évite en partie les problèmes de calage géométrique liés à des sources différentes, ainsi que les problèmes de non simultanéité temporelle que l'on rencontre lorsque l'on utilise des images acquises à des dates très éloignées.

5.3.1 MNH – Informations sur la présence de hauts couverts

Les données du MNH brut ne peuvent pas être directement utilisées comme moyenne car la valeur numérique de 0m du sol ferait perdre son sens aux calculs de hauteur moyenne sur une zone, il faut décomposer l'information du MNH en plusieurs indicateurs. Trois indices sont proposés afin d'exploiter au maximum le potentiel de la couche MNH.

Le premier indice est une moyenne de hauteur. Il représente la moyenne de hauteur des pixels de sursol uniquement ($h > 0$) dans le segment. Il doit permettre de classer les parcelles selon leur type d'arbre et leur hauteur. Le second représente de manière similaire l'écart type des valeurs de hauteur et permet d'évaluer la variabilité intra-parcellaire. Le troisième indice représente quand à lui une « proportion de sursol », il rend compte du pourcentage de surface dans chaque objet étant classé dans la catégorie sursol (c'est-à-dire de hauteur non nulle). Il devrait permettre de quantifier la fermeture du couvert dans les parcelles d'agroforesterie.

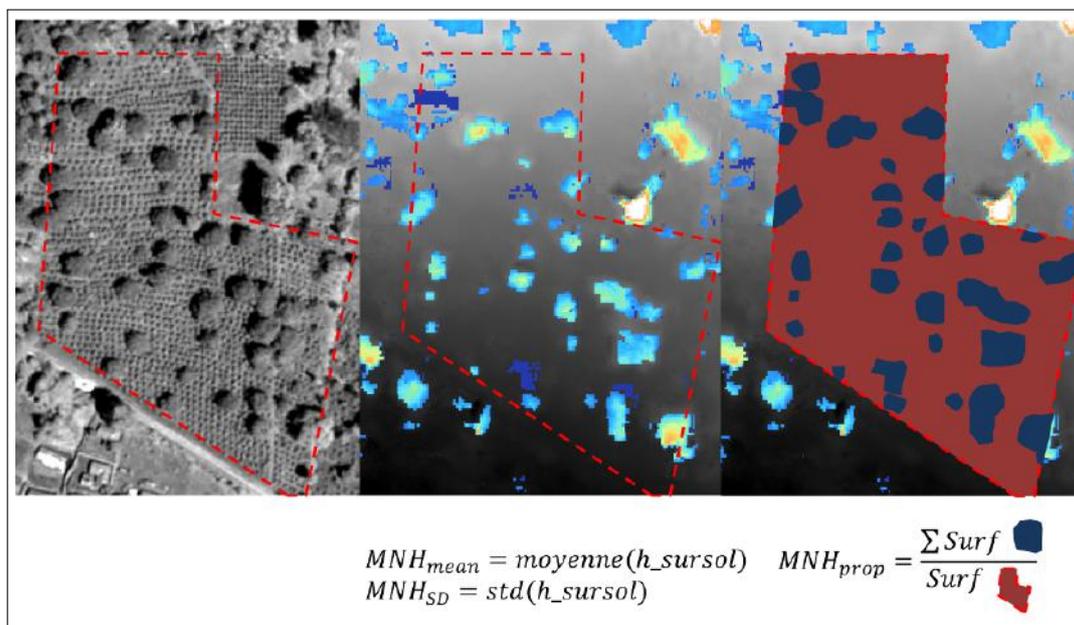


FIGURE 5.2 – Création des indices dérivés du MNH

Le figure 5.2 illustre une nouvelle fois le fait que la hauteur des cafés est très difficile voire impossible à extraire sur un MNS stéréoscopique. Ils apparaîtront ainsi à 0m sur le MNH et ne pourront pas influencer sur la classification.

5.3.2 NDVI – Discrimination des parties végétales

Le NDVI (Normalized Difference Vegetation Index) est un indice arbitraire spécifiquement créé pour discriminer la végétation. Il se base sur un calcul de pente entre la valeur de réflectance dans le rouge et celle dans l'infrarouge (NIR), valeur qui caractérise particulièrement la végétation. Il se calcule grâce à la formule $NDVI = \frac{NIR - R}{NIR + R}$.

D'autres formules existent (tels que l'EVI ou le GDVI), créées pour être utiles dans des problèmes plus particuliers, on décide dans notre étude de s'en tenir à la formule de base. Le NDVI est ainsi particulièrement efficace pour distinguer la végétation du reste comme le montre la figure ci-contre. L'indice ne se révèle cependant efficace qu'avec une approche objet, il est alors possible de séparer nettement

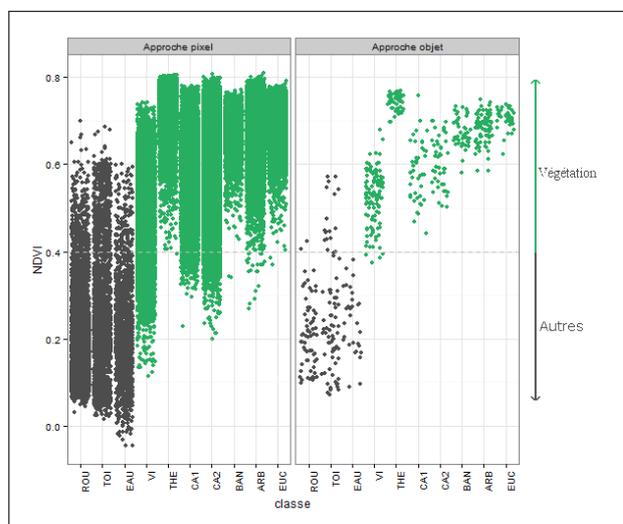


FIGURE 5.3 – Discrimination de la végétation par le NDVI

les deux classes en adoptant un seuil arbitrairement fixé à 0.4. La radiométrie d'une partie des toits bleus reste cependant au-dessus de cette valeur, nous avons par conséquent décidé d'utiliser le bleu comme seuil complémentaire afin d'écartier les derniers objets potentiellement mal classés. Il en résulte alors une classification binaire, nous pourrions retravailler par la suite sur la partie végétale exclusivement.

5.3.3 Indices texturaux – Information sur les éléments structurants des objets

Les indices texturaux rendent compte de l'organisation géométrique des pixels dans une matrice, ils permettent alors de mettre en évidence des éléments structurants dans des surfaces hétérogènes, comme par exemple l'alternance radiométrique que l'on retrouve dans les parcelles de cafés organisées en rangs.

Le choix s'est porté ici sur les indices d'Haralick issus des matrices de co-occurrence sur des images en niveau de gris (Gebejes and Huertas, 2013), ce sont les indices de texture les plus simples à générer et ceux-ci donnent habituellement de bons résultats pour distinguer des systèmes de culture différents en milieu complexe. Nous décidons de calculer les indices sur l'image panchromatique qui possède la meilleure résolution, on pourrait aussi envisager l'utilisation des bandes de l'image multi spectrale mais cette possibilité n'a pas été testée dans ce travail. Il reste alors le choix de la fenêtre utilisée pour les calculs, plus la fenêtre est grande, plus les motifs mis en évidence seront grands. Les tailles de fenêtres sont alors déterminées selon la taille des motifs que l'on veut repérer. La taille la plus faible utilisée sera de 9 pixels, soit 4.5m, c'est-à-dire la distance entre deux rangs de cafés. On garde ensuite des indices à 31 pixels (15.5m) pour les motifs des petits arbres et des indices à 51 pixels (25.5m) pour les grands motifs (principalement pour différencier couvert arboré et bananier). Il existe 8 indices d'Haralick différents générés par le logiciel ENVI, soit 8 bandes par taille de fenêtre. Nous utiliserons dans notre étude la totalité de ces indices.

5.4 Etape de segmentation

L'adoption de l'approche objet implique que l'on possède au préalable une séparation de l'espace à classifier en objets homogènes. Cette étape est plus communément appelée une segmentation et est cruciale pour la réussite de la suite des opérations. En effet, les objets doivent être suffisamment homogènes pour faciliter la tâche des algorithmes de classification qui vont s'appliquer dessus.

Le choix s'est porté sur le logiciel Ecognition, dont des jetons sont communément disponibles à la MTD. Ce logiciel permet de réaliser une segmentation à plusieurs niveaux et de réaliser des classifications simples sur la pile de rasters chargés dans le logiciel. Le ruleset détaillé est présenté en détail en annexe, celui-ci réalise une segmentation fine sur le NDVI et le panchromatique avant de classifier les zones de non végétations. Les zones non classées sont alors utilisées dans une nouvelle segmentation produisant des objets de taille plus importante. Le facteur de taille a été fixé après expérimentations à 60, sachant que la segmentation porte sur une combinaison des bandes multi spectrales à 200 cm et de la bande panchromatique à 50 cm. Les indices de texture, bien qu'intéressants, ne sont ici pas utilisés car ils ne respectent pas les bords naturels des objets que l'on veut délimiter.

Les temps de calcul (segmentation et rééchantillonnage) sur Ecognition peuvent être longs, il a par conséquent été décidé de n'utiliser qu'une petite partie de la région pour les tests.

Etant donné le gradient de cultures Est-Ouest qui règne dans la région, il n'est pas possible de sélectionner une petite zone unique assez représentative. On décide donc de choisir 5 zones de 1km de côté réparties dans la région.

Une fois la segmentation réalisée, il est possible d'exporter les polygones sous format shapefile. La table attributaire contient alors pour chaque polygone la valeur moyenne pour chaque bande ainsi que les 3 indices MNH mentionnés dans la figure 5.2

5.5 Le choix de la classification supervisée

5.5.1 Supervisé ou non supervisé : les deux grands familles de classification

Nous avons déjà fait le choix dans un paragraphe précédent de l'approche objet car c'est celle qui est la plus adaptée à nos données. Nous avons alors segmenté l'espace en objets de taille similaire. Il reste alors à assigner une classe à tous ces segments selon la valeur des attributs contenus dans leur table attributaire. Dans le domaine de l'apprentissage automatique pour la classification, on dénombre deux familles d'algorithmes :

- Ceux du type classification supervisée auxquels il faut fournir des données de référence (c'est-à-dire une matrice d'attributs et une colonne classe) pour qu'ils puissent « apprendre » et en déduire des règles. (Random Forest, SVM...) Le but est de prédire la classe d'un objet en fonction d'un certain nombre d'attributs, sachant que l'on connaît la classe d'échantillons d'apprentissage avec les mêmes attributs.
- Ceux du type classification non supervisée n'utilisant pas de données d'apprentissage (K-means, Classification Ascendante Hiérarchique...). L'algorithme décide (totalement ou partiellement) lui-même des classes à l'aide d'indicateurs statistiques estimés (souvent par la méthode des moments)

On fait le choix ici d'un apprentissage supervisé, choix motivé par plusieurs raisons. Tout d'abord, l'existence préalable de données terrain nous permet d'obtenir assez rapidement une base d'apprentissage remobilisable. De plus, le nombre important de classes et leur différence de poids rend périlleux la découpe automatique en classes de l'échantillon (certaines classes comme le vivrier couvrent possèdent des signatures très étendues tandis que d'autres comme les caféiers montrent une signature très spécifique). C'est ce que nous allons voir en créant une base d'apprentissage et en réalisant une étude préliminaire sur l'espace créé par ses attributs.

5.5.2 Jeu d'apprentissage

Si la segmentation est cruciale à la réussite d'une classification avec apprentissage, l'échantillon d'apprentissage l'est aussi (au-delà du choix des classes qui est l'étape la plus critique). Plusieurs questions se posent nécessairement quant à la nature de l'échantillon.

La première question porte sur la taille du jeu d'apprentissage, c'est-à-dire le nombre d'objets à l'intérieur. La taille de l'échantillon optimale est difficile à déterminer. Si l'on peut affirmer sans trop de doute, que, en théorie, un échantillon plus grand avec la même assurance qualité sera statistiquement meilleur, il est difficile de situer la frontière à partir de laquelle rajouter des échantillons sera superflu par rapport à la précision voulue. Nous avons pris en compte ici les échantillons par classe, en intégrant la séparation en deux de l'échantillon afin de réaliser une validation croisée (deux échantillons totalement indépendants). Afin d'évaluer la précision pour chaque classe, nous avons fixé arbitrairement un minimum de 30 échantillons minimum par classe, ce qui nous donne un total d'environ 500 échantillons compte tenu du nombre de

classes qui nous intéresse.

La deuxième question porte sur la surface des polygones de vérité, qui n'est pas forcément la même que pour celles des polygones de la segmentation. Il est préférable d'utiliser des segments dont la taille est comparable à celles de ceux produits par segmentation. La question se pose tout particulièrement quand on utilise des indices de texture.

La troisième question porte sur la manière de générer le jeu d'apprentissage. Les deux solutions sont couramment la photo-interprétation (délimiter par-dessus un raster les polygones) et la vérité terrain (relever des points GPS sur le terrain). Le choix est souvent influencé par les données déjà disponibles, nous possédons par exemple déjà une base de vérité terrain. La vérité terrain est par définition en théorie exacte mais contient aussi peut-être une information qui n'existe pas dans les attributs utilisés pour l'apprentissage, d'où un risque de classes précises mais mal prédites. A contrario, l'information définie par photo-interprétation est normalement cohérente avec l'information contenue dans les attributs, il y a cependant un risque d'erreur dans l'interprétation thématique de ce qui est vu par l'opérateur, même dans le cas de la THRS.

Pour créer le jeu de données qui servira à l'apprentissage, trois solutions s'offrent à nous :

- Utiliser la segmentation réalisée sur les 5 vignettes test et assigner manuellement les classes aux polygones contenus dans leurs limites
- Utiliser la base de données terrain contenant des polygones et leur classe pour environ 2000 entités. La classification est cependant différente de la notre et les différents segments sont de taille variable, du moins ne sont pas forcément comparables à la taille des segments issus de la segmentation.
- Créer soi-même le jeu d'apprentissage en délimitant tous les éléments à la main

On décidera de repartir de la base terrain en redessinant tout de même à la main les polygones. Le problème de l'équilibrage des classes peut aussi se poser, nous avons essayé dans la mesure du possible d'utiliser des classes d'effectif, si non proches, au moins à l'échelle comparable. Le jeu d'apprentissage comporte ainsi 466 échantillons associés à des classes végétales. Le détail de répartition des classes dans le jeu d'apprentissage est précisé en annexe. D'autres échantillons sur les 3 classes non végétales ont été délimitées mais ne furent au final pas utilisés car le NDVI séparait déjà bien ces classes de la végétation. La figure 5.1 présente quelques exemples d'échantillons et la classe qui leur est associée.

5.6 Choix de l'algorithme implémenté

Etant donnés les défis liés au « data mining » la littérature concernant les algorithmes de classification supervisée est pléthorique. Son utilisation est cependant plus rare dans le cadre d'une problématique agricole bien qu'il existe de nombreux exemples de classification supervisée pour l'agriculture et l'environnement (Rodriguez et al., 2006; Tatsumi et al., 2015). Les algorithmes existants varient significativement en complexité et en paramétrage. De manière générale, il existe une volonté de pallier aux limitations de la séparation d'un espace à l'aide d'une contrainte linéaire. Parmi les algorithmes inventés dans ce but, certains utilisent l'aléatoire et de la répétition pour obtenir de meilleurs résultats (Random Forest), d'autres séparent l'espace des variables à l'aide de fonctions plus complexe (SVM). Ces deux algorithmes parmi les plus populaires actuellement seront utilisés pour conduire la classification.

5.6.1 Random Forest (RF)

Le Random Forest se base sur le principe des arbres de décision (Breiman, 2001). Le but est d'éliminer les défauts des arbres de prédiction en construisant un grand nombre d'arbres de décisions (partitionnement de l'espace) avec à chaque fois un échantillon d'apprentissage différent. On peut alors faire de la prédiction à l'aide de ces arbres, la classe prédite étant déterminée par un vote à la majorité sur les résultats obtenus sur tous les arbres. Cet algorithme est efficace sur les jeux de données avec un grand nombre de dimensions ou avec un grand nombre d'échantillons d'apprentissages à la répartition parfois déséquilibrée (Chen et al., 2004).

5.6.2 SVM

La classe des algorithmes SVM sépare l'espace à l'aide d'une frontière de décision pouvant ne pas être linéaire. Elle se base sur le principe des Support Vector, points particuliers définissant le mieux la frontière entre deux classes. Le SVM vise à résoudre un problème d'optimisation et peut par conséquent être lent sur certains jeux de données contenant un grand nombre d'échantillons. L'utilisation et l'interprétation de SVM peut être déroutante en raison des nombreux paramètres ajustables et de l'abstraction de la théorie le régissant, mais on retrouve dans la littérature de nombreux travaux tentant de clarifier la compression du SVM et l'interprétation de ses résultats (Do).

Une description plus complète du fonctionnement de ces deux algorithmes est présentée en annexe.

Conformément au théorème No free lunch (Wolpert, 1996) appliqué aux algorithmes d'apprentissage, il n'existe pas d'algorithme réalisant une optimisation fondamentalement supérieure aux autres dans tous les cas. Il est nécessaire de déterminer au cas par cas quel est l'algorithme le plus adapté aux données, ce qui justifie la conduite de tests comparant plusieurs d'entre eux.

5.6.3 Implémentation logicielle des algorithmes de classification

L'implémentation des algorithmes RF et SVM se fait sur R. R est un langage libre dont les scripts sont facilement échangeables, les avantages sont son orientation statistique et les possibilités de vectorisation qu'il offre. Les deux algorithmes sont facilement accessibles à l'aide de packages contenant des fonctions pour l'apprentissage et l'analyse des résultats. Il existe de nombreuses fonctions ou packages dédiés, nous avons décidé d'utiliser les plus courants, à savoir respectivement RandomForest et e1071 (Karatzoglou et al., 2006). De même R supporte aussi le traitement des données vecteur et raster ce qui nous permet d'étoffer la palette de possibilité pour le traitement et la visualisation des étapes de classification avant de transmettre les résultats à un SIG.

Il est intéressant de noter que cette démarche n'est pas linéaire mais que des allers-retours successifs ont été nécessaires pour ajuster la démarche selon les résultats des tests, ce qui peut vite devenir une contrainte opérationnelle.

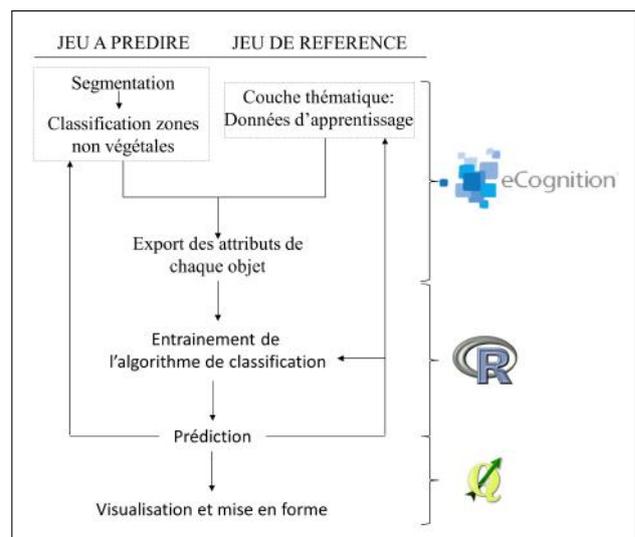


FIGURE 5.4 – Implémentation algorithmique de la chaîne de classification

6.1 Résultats de la classification supervisée

6.1.1 Méthodes utilisées pour évaluer les résultats Création d'indicateurs quantitatifs et visuels

Les algorithmes de classification nous donnent en sortie un modèle applicable à un jeu de données afin d'obtenir un vecteur de classes prédites. De nombreux paramètres peuvent jouer sur la qualité des résultats, il est donc nécessaire d'avoir des indicateurs chiffrés pour comprendre et améliorer ces résultats. Tout d'abord, il est nécessaire d'adopter ici une démarche de validation robuste. On utilise une technique de validation classique : celle-ci consiste en la séparation du jeu de données initial en une partie dédiée à la classification et une partie dédiée à la validation. La fission du jeu de données se fait aléatoirement et les deux parties (d'effectif égal ou non) sont normalement indépendantes. Ainsi les segments ayant servis à entraîner ne seront pas utilisés pour la validation. L'inconvénient est que cela diminue la taille du jeu de validation.

La matrice de confusion est l'indicateur quantitatif le plus répandu. Il consiste tout simplement à exprimer, pour chaque classe de référence, la quantité de chaque classe prédite. Ainsi, la diagonale de la matrice correspond au nombre de segments bien prédits pour chaque classe. L'avantage de la méthode est qu'elle permet de voir individuellement où se trouvent les confusions. Il est aussi possible de faire la moyenne des précisions sur chaque classe afin d'en tirer un indice global, plus facilement comparable à d'autres instances de classification. Il existe une part importante d'aléatoire dans l'algorithme Random Forest. Cependant, chaque occurrence du Random Forest est déjà la répétition d'un grand nombre d'arbres de décisions. Il n'est donc pas étonnant de constater qu'au bout de 100 lancements du Random Forest, l'écart type des taux de succès observés est inférieur à 0.5%, signe que plus de répétitions ne sont pas nécessaires.

Les résultats de classification seront aussi utilisés sur les 5 petites régions-test de 1km² de coté représentatives de la diversité de la région. Ces mini-vignettes devraient permettre de mieux juger la qualité de la classification sur une zone non discontinue contenant plusieurs milliers de polygones à prédire. Pour les classifications utilisant seulement l'image Worldview, il n'existe pas de classification à certains endroits car l'empreinte de l'image est plus restreinte. De même les zones de non végétation sont aussi laissées en blanc. La localisation de ces zones est indiquée en annexe.

Les tests sont alors effectués sur différentes subdivisions du jeu de données de base (chacune correspondant à l'acquisition d'un certain nombre d'images) avec différents algorithmes. On retrouve 2 algorithmes basés sur le Random Forest, l'un utilisant pour chaque arbre \sqrt{n} attributs (n étant le nombre total d'attributs) et l'autre utilisant tous les attributs. De même, 4 implémentations du SVM ("Linear", "Radial", "Polynomial", "Sigmoid") sont utilisées, chacune correspondant à une fonction noyau différent.

6.1.2 Test des différents algorithmes sur une acquisition Worldview 2 ou Pléiades

Prenons d'abord le cas où l'utilisateur ne souhaite/peut acheter qu'une seule image satellite. On ne considérera alors qu'une acquisition unique de Murang'a par le satellite Worldview (8 bandes multispectrales) ou le satellite Pléiades (4 bandes multispectrales). Il est possible avec

cette acquisition de récupérer des indices de textures en plus des bandes spectrales existantes, la 3D n'est cependant pas envisageable. Le pourcentage de succès est alors calculé pour chaque type d'algorithme et pour l'une des deux images, soit en tout 12 valeurs de précision.

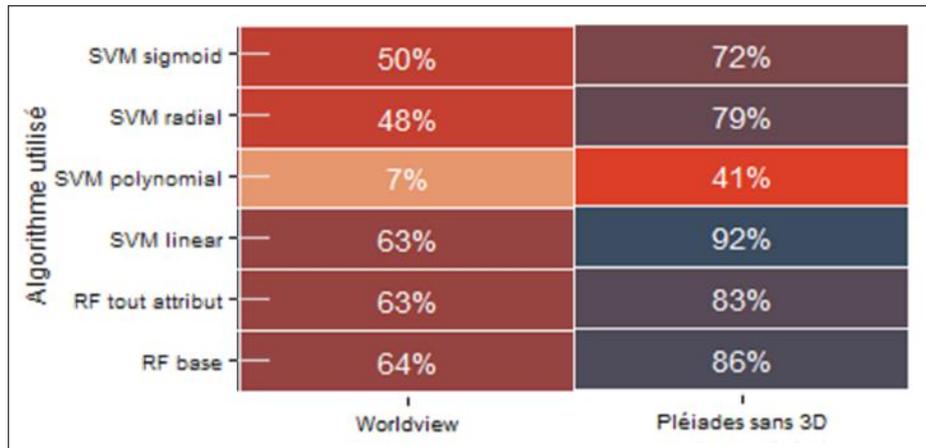


FIGURE 6.1 – Comparaison de précision de classification globale entre les données issues d'une seule acquisition Pléiades ou Worldview 2

Le résultat est ici sans appel et reste vrai quelque soit l'algorithme : la donnée Pléiades prédit mieux le jeu de validation, avec une différence de score significative allant de 20% à 30%. Un tel résultat peut paraître paradoxal car l'image Worldview est théoriquement radiométriquement plus riche, possédant 5 bandes en plus pour séparer avec plus de finesse des classes très proches. Nous pouvons faire l'hypothèse que certaines bandes sont corrélées et apportent la même information de discrimination des classes. Cependant il est difficile de donner du sens à ce résultat quand on sait que les deux images n'ont pas été acquises à la même date, en sachant que l'image Pléiades est la plus récente et donc théoriquement la plus exacte par rapport aux données d'apprentissage (les données de validation ont été recalées à la main sur l'image Pléiades). Un premier tableau renseignant l'importance de chaque bande pour la différenciation des classes est présenté en annexe. Celui-ci n'est cependant disponible que pour l'algorithme Random Forest, le SVM ne proposant pas l'extraction d'indices d'importance. Quand aux algorithmes, les tests sont dominés par le Random Forest et le SVM à noyau linéaire. Le noyau "Polynomial" prédit très mal les classes tandis que les noyaux "Sigmoid" et "Radial" produisent un score moyen aux alentours des 50%. Dans ce cas précis, ce test prouve que le Random Forest utilisé avec des paramètres de base est plus adapté. Il indique aussi la nature du noyau SVM le plus adapté mais une explication visant à expliquer ce succès dépasse le cadre de ce mémoire.

Détaillons la matrice de confusion pour le meilleur algorithme sur Pleiades et le meilleur algorithme sur Worldview 2 :

TABLE 6.1 – Matrice de confusion pour les meilleurs algorithmes Pléiades et Worldview 2

Pléiades - SVM linear							Worldview2 Random Forest								
57	0	0	0	0	0	0	VI	27	2	0	1	0	1	0	VI
1	19	0	0	0	0	0	THE	2	8	0	0	0	1	0	THE
0	0	27	1	0	0	0	CA1	0	0	9	0	0	1	0	CA1
0	0	0	28	0	1	0	CA2	0	0	2	10	1	3	2	CA2
0	0	1	1	14	0	0	BAN	0	0	0	1	7	0	0	BAN
0	0	0	2	1	59	7	ARB	0	2	0	3	1	19	4	ARB
0	0	0	0	0	0	10	EUC	0	0	0	0	0	2	2	EUC
VI	THE	CA1	CA2	BAN	ARB	EUC	VI	THE	CA1	CA2	BAN	ARB	EUC		

L'interprétation est difficile car le jeu de validation Worldview est plus restreint. On retrouve cependant dans les deux cas une meilleure capacité à prédire les classes non-agroforestières, bien qu'il reste encore des confusions dans le cas de Worldview 2. Les deux algorithmes ont des difficultés à distinguer les classes ARB, CA2 et BAN, ce qui renforce l'idée selon laquelle des données complémentaires sont nécessaires pour mieux les discriminer. Nous allons maintenant nous pencher sur la classification des zones test.

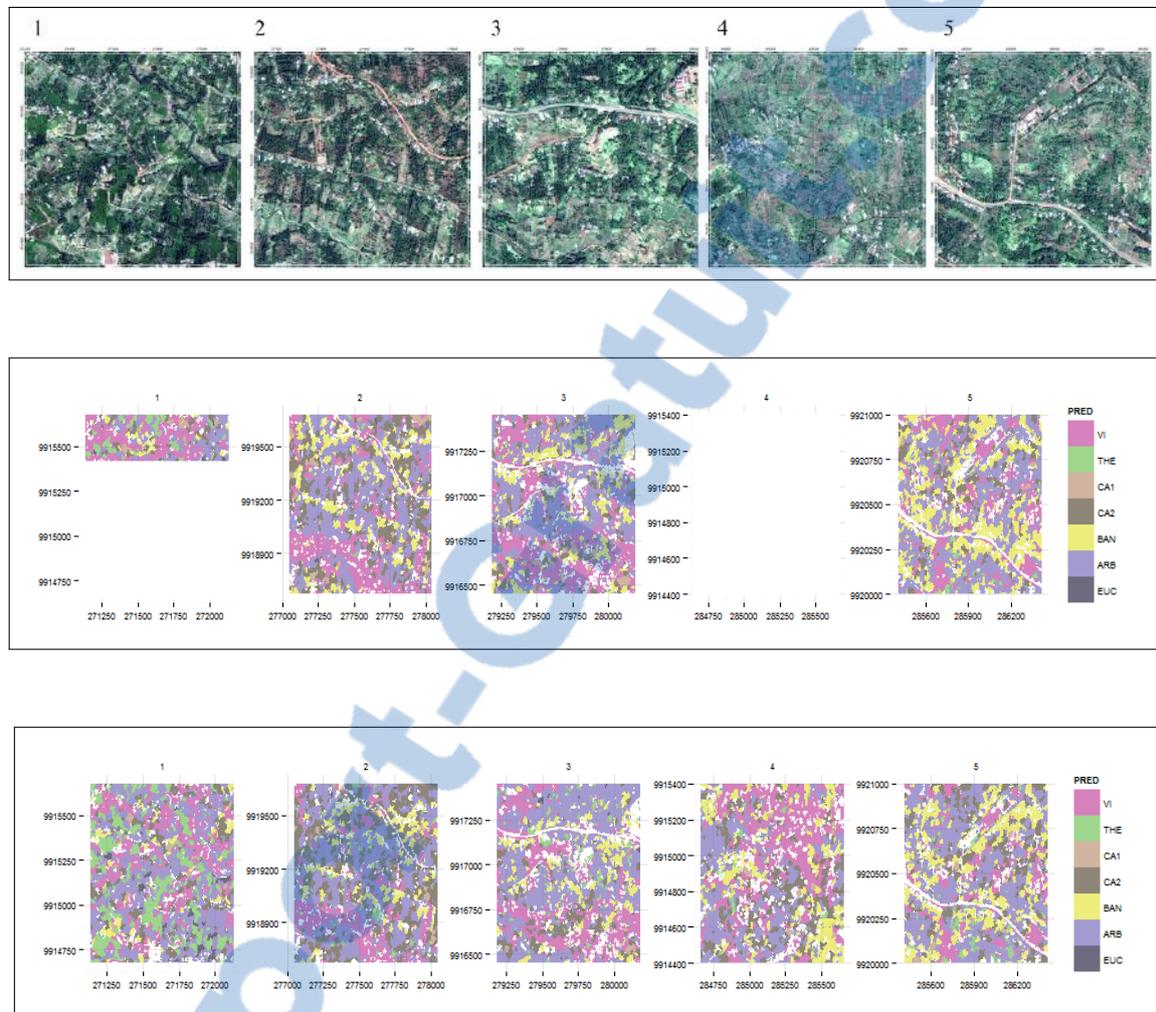


FIGURE 6.2 – Haut : Image Pansharpning Pléiades des zones de test
Milieu : classification à partir des données Worldview 2 sur la base de l'algorithme au meilleur score

Bas : classification à partir des données Pléiades sur la base de l'algorithme au meilleur score

L'hétérogénéité entre deux zones agricoles différentes est facilement visible à l'aide de ce type de représentation. On remarque cependant qu'il existe des erreurs, plus importantes que pour l'évaluation du jeu de validation. Cela illustre un phénomène courant en classification, qui tient son explication dans le fait que les échantillons sélectionnés pour l'apprentissage et la validation sont en moyenne beaucoup moins « incertains » que la totalité des objets d'une zone. Beaucoup d'objets sont, même à l'œil nu, difficiles à classer avec certitude. Ici c'est particulièrement vrai pour les bananiers qui semblent être la classe préférée par l'algorithme en cas de zone « floue », sans doute à cause de leur signature radiométrique ou texturale. On remarque aussi la présence non voulue de quelques parcelles de théiers à la place d'herbe napier et une classe Café ombrage englobant beaucoup de parcelles devant être classées comme Système arboré. Le véritable défi est ici de déterminer si ces erreurs sont significatives et

peuvent fausser les interprétations réalisées dessus, une des solutions serait de reprendre la méthodologie d'évaluation et de l'appliquer sur un jeu de validation couvrant les 5 zones de classification entières.

Nous retrouvons des tendances assez similaires selon l'image utilisée, la principale différence visuelle étant que l'on retrouve plus de bananiers dans la classification Worldview. Si l'on devait les comparer pour la tâche de classification, on en viendrait à la conclusion que l'image Pléiades est plus adaptée.

Lorsque nous considérons Worldview 2, il est bien sûr nécessaire de considérer le fait qu'il existe une différence de prix entre l'acquisition d'une image Worldview et celle d'une image Pléiades pouvant nuancer les résultats de classification.

6.1.3 Introduction des données 3D dans la classification Pléiades

Nous arrivons alors sur un deuxième cas dans lequel l'utilisateur décide d'acquérir 3 images Pléiades, donc de tripler son investissement. Nous examinons alors l'amélioration qui en résulte. Dans le cas du Random Forest, la précision globale passe de 86% à 87% tandis que le SVM voit son pourcentage stagner. L'augmentation est constatée dans 1 cas mais elle n'est pas significative. Il est intéressant de noter que les autres noyaux du SVM profitent bien plus des données 3D (jusqu'à +12% pour le "Sigmoid") mais le taux de succès reste trop faible. Encore une fois ici, le taux de succès est cependant global et ne pondère pas l'importance que l'on donne aux classes (les classes liées à l'agroforesterie étant plus importantes).

SVM sigmoïd	72%	84%
SVM radial	79%	85%
SVM polynomial	41%	43%
SVM linéaire	92%	92%
RF tout attribut	83%	85%
RF base	86%	87%
	Pléiades sans 3D	Pléiades avec 3D

FIGURE 6.3 – Apport de la 3D pour la précision globale

Reprenons ces deux meilleurs algorithmes et détaillons alors les deux matrices de confusion avant l'introduction des données 3D et voyons comment le nombre d'échantillons bien classés augmente pour chaque classe :

TABLE 6.2 – Evolution de la matrice de confusion avec l’insertion des variables 3D

Random Forest							Linear SVM							
58	0	0	0	0	0	0	57	0	0	0	0	0	0	VI
0	18	0	0	0	1	0	1	19	0	0	0	0	0	THE
0	0	26	1	0	0	0	0	0	27	1	0	0	0	CA1
0	0	0	24	0	5	3	0	0	0	28	0	1	0	CA2
0	0	1	1	14	1	0	0	0	1	1	14	0	0	BAN
0	1	0	6	1	53	3	0	0	0	2	1	59	7	ARB
0	0	0	0	0	0	11	0	0	0	0	0	0	10	EUC
VI	THE	CA1	CA2	BAN	ARB	EUC	VI	THE	CA1	CA2	BAN	ARB	EUC	

Introduction de la donnée 3D														
0	0	VI
.	0	0	THE
.	.	0	+1	CA1
.	.	.	+1	-2	.	.	.	CA2
.	.	.	.	+1	+1	.	.	BAN
.	+3	+5	.	ARB
.	-1	-2	EUC
VI	THE	CA1	CA2	BAN	ARB	EUC	VI	THE	CA1	CA2	BAN	ARB	EUC	

Les résultats précédents prennent un peu plus de relief grâce à ces détails. Les données 3D se sont montrées le plus efficaces sur les classes agroforestières, tout particulièrement la classe couvert arboré. D’autres classes en ont cependant mal bénéficié comme les plantations d’eucalyptus. A l’inverse, il n’est pas étonnant de voir que la 3D ne change rien à la reconnaissance des classes non boisées. Des interprétations supplémentaires sont ici nécessaires pour comprendre ce qui se passe. Nous allons pour cela repartir du jeu d’apprentissage et présenter plusieurs cas où la 3D a permis la discrimination et des cas où la 3D a induit une erreur.

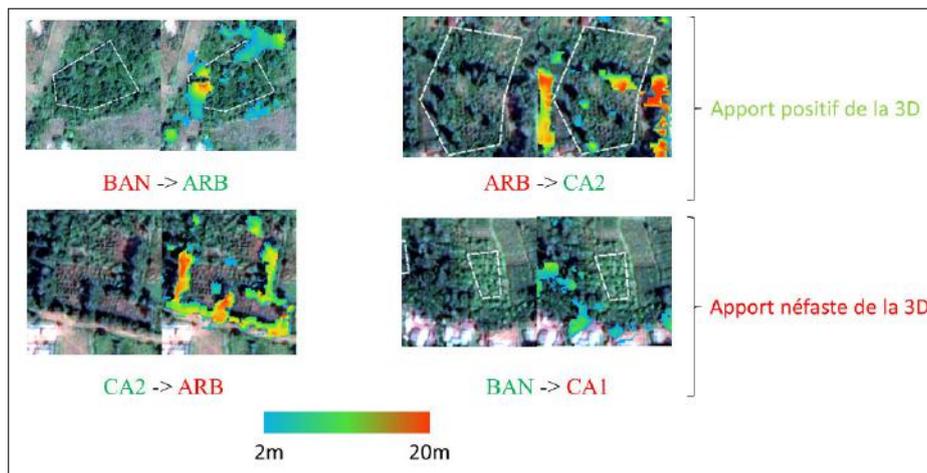


FIGURE 6.4 – Illustration de l’effet néfaste des données 3D sur la classification à l’aide de l’image Pléiades et du MNH

Dans la figure 6.4 sont indiqués par une flèche certains changements de classe, qu’ils soient positifs ou non. On remarque ici que la donnée est à double tranchant. Lorsque la 3D est présente, celle-ci peut aider à la détection d’un couvert arboré qui ne ressortirait pas assez par les indices de texture et la radiométrie. Cependant l’inconsistance de la présence du sursol

sur le MNH rend les 3 critères dérivés potentiellement trompeurs. Ainsi ici, une trop bonne cartographie du sursol aura fait pencher l'algorithme en faveur d'un couvert arboré alors que la parcelle se composait de café sous ombrage. A l'opposé, le manque d'information d'altitude sur une portions de bananiers aura poussé l'algorithme à le classer en tant que caféiers au soleil, culture qui n'a normalement aucun sursol détectable. Il est certes possibles d'améliorer la discrimination de parcelles agroforestières grâce au MNH mais cela semble nécessiter un MNH plus consistant sur lequel appliquer des règles robustes, ce qui ne semble pas être le cas ici.

Tout de même, la question est clairement de savoir si la très légère amélioration globale constatée (typiquement 1/10 des mal-classés corrigés) vaut l'investissement. La question ne se pose bien sûr que pour les études de milieux densément peuplés en arbres, la donnée serait impuissante face à l'étude des grandes cultures par exemple.

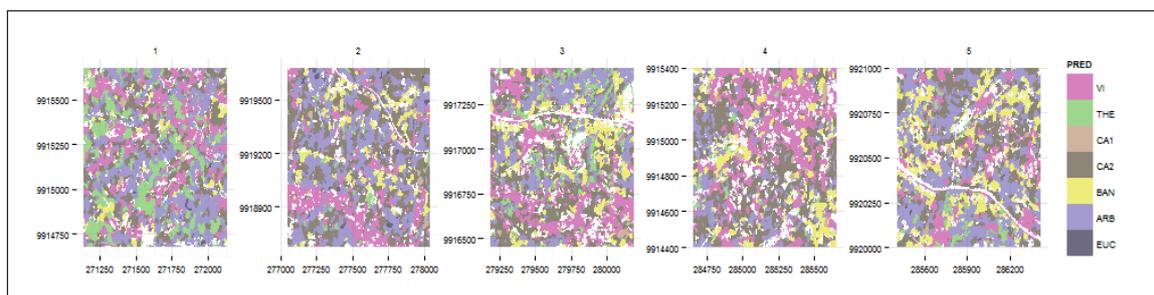
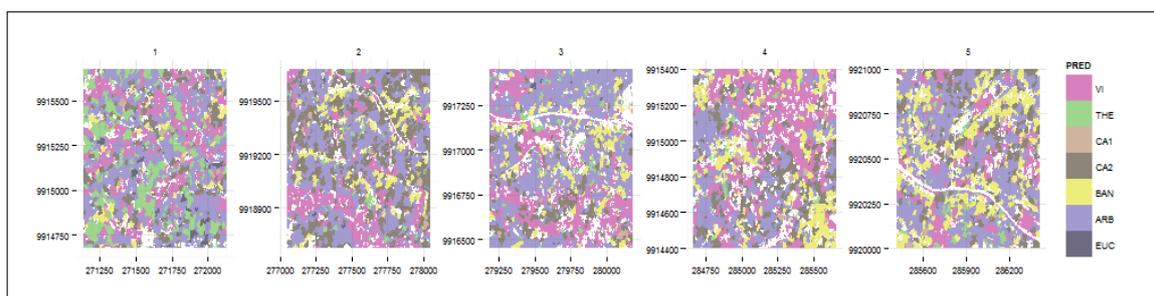
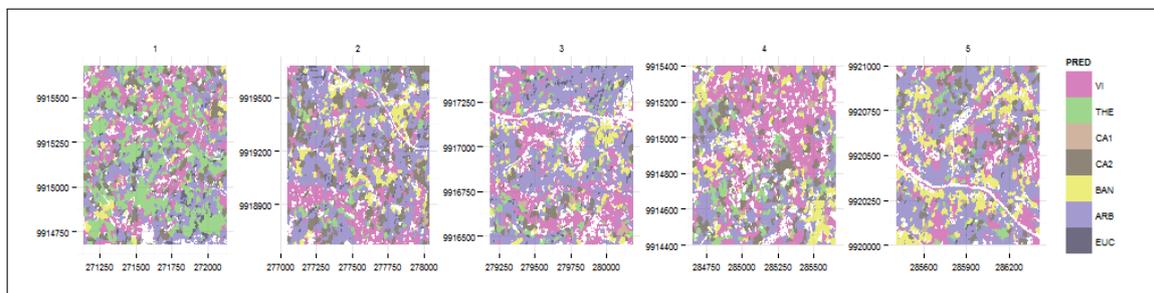


FIGURE 6.5 – Haut : classification à partir des données Pléiades sans 3D sur la base de l'algorithme SVM linéaire Bas : classification à partir des données Pléiades avec 3D sur la base de l'algorithme SVM linéaire



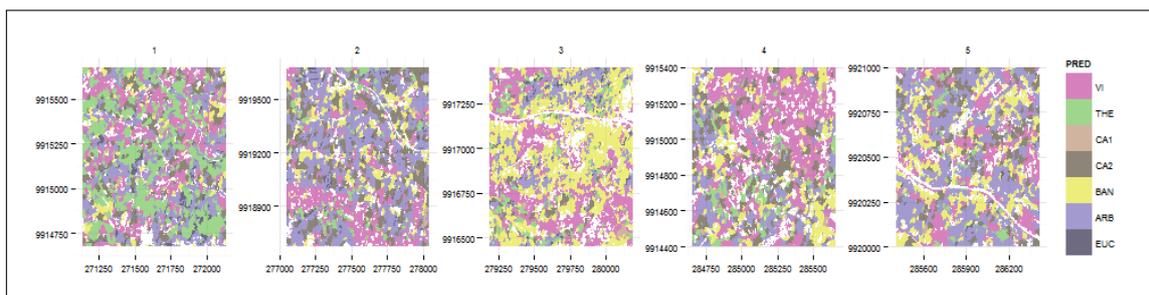


FIGURE 6.6 – Haut : classification à partir des données Pléiades sans 3D sur la base de l'algorithme Random Forest Bas : classification à partir des données Pléiades avec 3D sur la base de l'algorithme Random Forest

Dans la plupart des cas, les différences sont subtiles. Elle est cependant spectaculaire dans le cas de la zone 3 traitée avec le Random Forest où la proportion de bananiers a anormalement augmenté, couvrant alors plus de la moitié de la zone 3. Un nouveau zoom sur l'image Pléiades de la zone s'avère ici nécessaire pour comprendre la nature de ce phénomène.

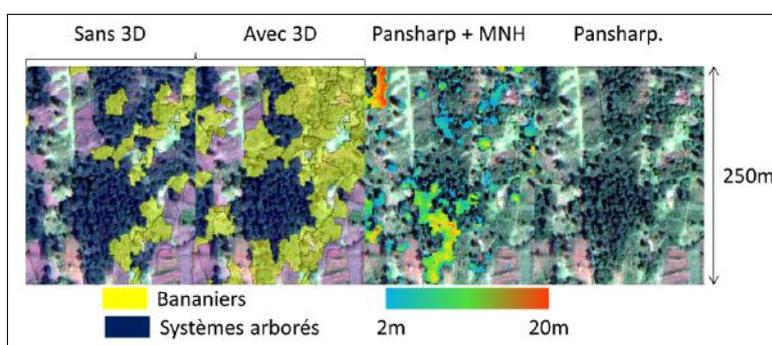


FIGURE 6.7 – Cas exemple de prolifération de la classe bananier avec le passage à la 3D (Random Forest)

Nous illustrons ici un cas général où la donnée 3D peut apporter une information néfaste à la classification. L'interprétation n'est cependant pas évidente car le terrain sur lequel on appliqué la classification est lui même complexe, il est important de rappeler que le MNS, et donc le MNH, créés sont relativement imparfaits et présentent des défauts tels que arbres voire des parties de massifs n'apparaissant pas. Les zones de bananiers sont tout particulièrement touchées par le problème ce qui peut constituer un premier facteur d'explication, même si cela ne permet pas de comprendre pourquoi le même phénomène ne subsiste pas avec SVM.

Détaillons enfin l'importance des 3 variables individuelles issues du MNH pour la discrimination de chaque type de classe. L'opération n'est ici possible que pour l'algorithme Random Forest.

De cette figure, on tire plusieurs informations importantes. Tout d'abord, la proportion en sursol semble être particulièrement importante pour toutes les classes arborées, sauf les bananiers. Au contraire, l'écart type sur la hauteur a la valeur la plus importante

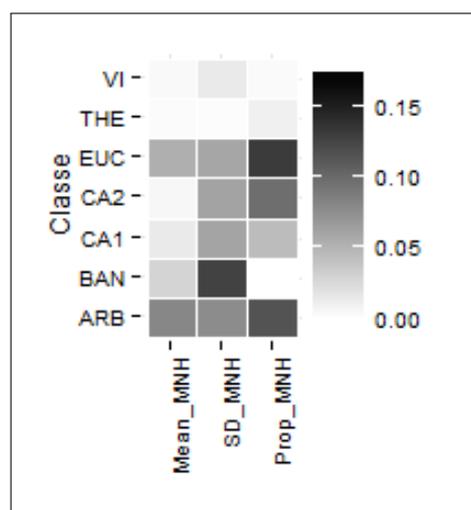


FIGURE 6.8 – Importance des variables du Random Forest - Sélection des variables MNH

pour les bananiers. Une des pistes pour améliorer les résultats serait donc la suppression de cet indice. Enfin la moyenne de hauteur est très logiquement importante pour la discrimination des couverts arborés et des plantations d'Eucalyptus.

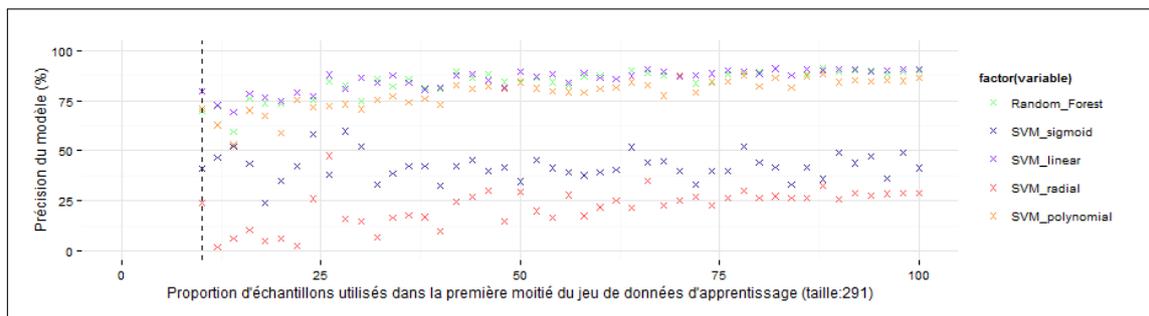


FIGURE 6.9 – Evolution du taux de succès de chaque algorithme en fonction de la taille de l'échantillon d'apprentissage

La figure 6.9 met quant à elle en évidence l'amélioration de la qualité de la classification avec le nombre de données utilisées pour l'apprentissage. Quel que soit l'algorithme choisi, il se révèle mieux fonctionner avec l'augmentation de ce nombre. On arrive cependant assez vite vers ce qui semble être un pallier au delà duquel le score des algorithmes ne progresse plus.

Nous pouvons imaginer une solution intermédiaire consistant à faire de la stéréo avec 2 images. Le choix des angles de visée est cependant encore plus critique pour la qualité comme nous l'avons vu au chapitre 4. Partant de cette incertitude initiale, il est difficile d'affirmer que la stéréo simple puisse donner d'aussi bons résultats que la tri-stéréo, c'est cependant une piste intéressante qui pourrait ôter 1/3 du prix de l'acquisition, budget pouvant être investi dans d'autres tâches.

6.1.4 Utilisation conjointe de Pléiades et de Worldview 2

Enfin nous mentionnons le cas où il est possible d'utiliser les deux types d'images, dans notre cas la commande de 4 images satellite en tout. C'est donc la solution la plus chère et aussi la plus compliquée à analyser car elle fait intervenir des sources différentes. Utiliser les deux ne semble pas améliorer le pourcentage de reconnaissance, le meilleur score obtenu étant aussi de 92%. Le résultat est logique car la similarité entre les bandes spectrales et texturales est très importante. Les seules bandes n'apportant pas une information redondante sont les bandes spectrales non présentes dans Pléiades.

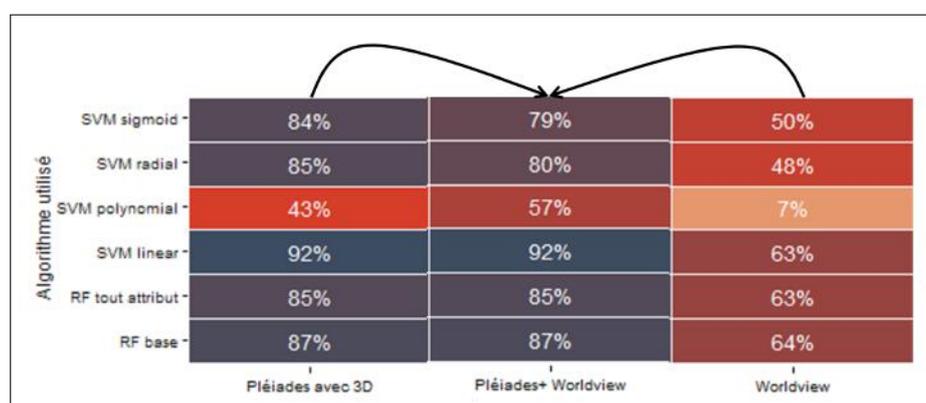


FIGURE 6.10 – Effet sur la précision globale de l'utilisation simultanée de Pléiades et Worldview 2

6.1.5 Application à tout Murang'a

La stratégie de classification jugée la plus intéressante (ici Pléiades modélisé par SVM avec noyau linéaire) est alors appliquée pour segmenter des régions entières. Quant au traitement, plus d'1 jour est nécessaire à Ecognition pour les premières étapes de segmentation et de classification. Les segments exportés sont ensuite exportés et les zones végétales sont alors soumises au modèle SVM linéaire. On obtient une carte de classification sur laquelle les segments voisins appartenant à la même classe sont fusionnés afin de diminuer le nombre de polygones du shapefile (très contraignants à afficher même pour une machine relativement puissante). Une carte précise de cette classification à très haute résolution a ainsi été générée. Cette version non définitive, car des ajustements sont encore à faire, peut être consultée en annexe. Plusieurs constats de validation peuvent être faits sur cette carte. Le premier constat concerne la proportion de chaque classe, renseignée dans le tableau suivant généré à l'aide du Plugin GroupStats sur Qgis.

Abrégé	Proportion (%)	Surface concernée (km ²)
VI	28	37
THE	6	7
CA1	1	2
CA2	16	22
BAN	14	19
ARB	35	48
EUC	<0.1	0.2
TOTAL=136		

Ici, la proportion en surface des cultures arborées et des cultures vivrières n'est pas étonnante. Celle en bananiers et en caféiers est plus surprenante et est peut-être indicatrice d'une mauvaise classification ou d'un manque de classes permettant de définir des zones à l'identité moins évidente. Nous décidons alors de confondre pour la représentation de la carte finale les bananiers et les systèmes arborés, afin de garantir une meilleure exactitude de la classification au prix de l'information de la séparation.

Si la classification finale sur tout Murang'a illustre visuellement bien les grandes tendances à l'échelle du paysages, elle reste moins convaincante en terme de précision. Il est ainsi difficile de proposer une validation chiffrée de cette précision, en sachant que les seules données de validation que nous possédons sont les 500 éléments des données délimitées manuellement à partir des données terrain.

6.2 Relations entre la classification et le relief de Murang'a

L'un des principaux objectifs du volet télédétection des projets auxquels cette étude se rapporte est la génération de cartes permettant de mieux comprendre l'organisation spatiale des systèmes de culture dans la région. Au-delà de la simple interprétation visuelle, qui apporte déjà des informations intéressantes sur la répartition des différents systèmes de culture et leur classification, on peut proposer des indicateurs issus de l'analyse spatiale de la carte guidée par les outils habituellement utilisés en écologie du paysage.

Au vu de nos premières interprétations et des travaux antérieurs, les clés de l'interprétation semblent très clairement être les gradients d'altitude et la répartition des cultures le long de ce gradient.

6.2.1 Répartition des cultures le long du gradient d'altitude

Considérons 3 classes d'altitude (extraites sur la donnée SRTM) correspondant aux 3 zones délimitées par (Toko, 2013) ,nous pouvons alors pour chaque classe d'altitude détailler la répartition, en surface, des classes agricoles qui y sont présentes.

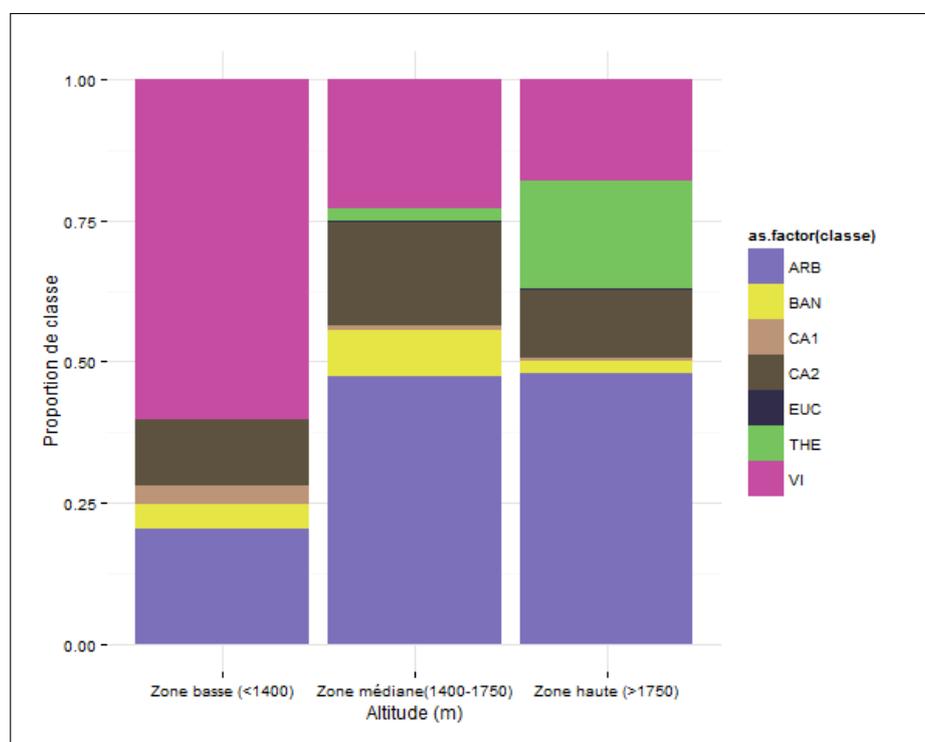


FIGURE 6.11 – Répartition des classes le long du gradient d'altitude

On retrouve dans cette figure les spécificités des 3 zones. Les cultures vivrières semblent être majoritaires dans la zone inférieure à 1400m pour laisser la place ensuite à des cultures arborées. A partir de 1750m, les théiers deviennent plus fréquents tandis que la part de caféiers diminue et celle du vivrier continue à décliner.

6.2.2 Répartition des cultures selon la pente locale du terrain

Considérons maintenant la pente (toujours en provenance du SRTM à 30m de résolution), nous pouvons aussi créer 3 classes de pente et calculer de la même manière la répartition en surface des classes agricoles qui y sont présentes.

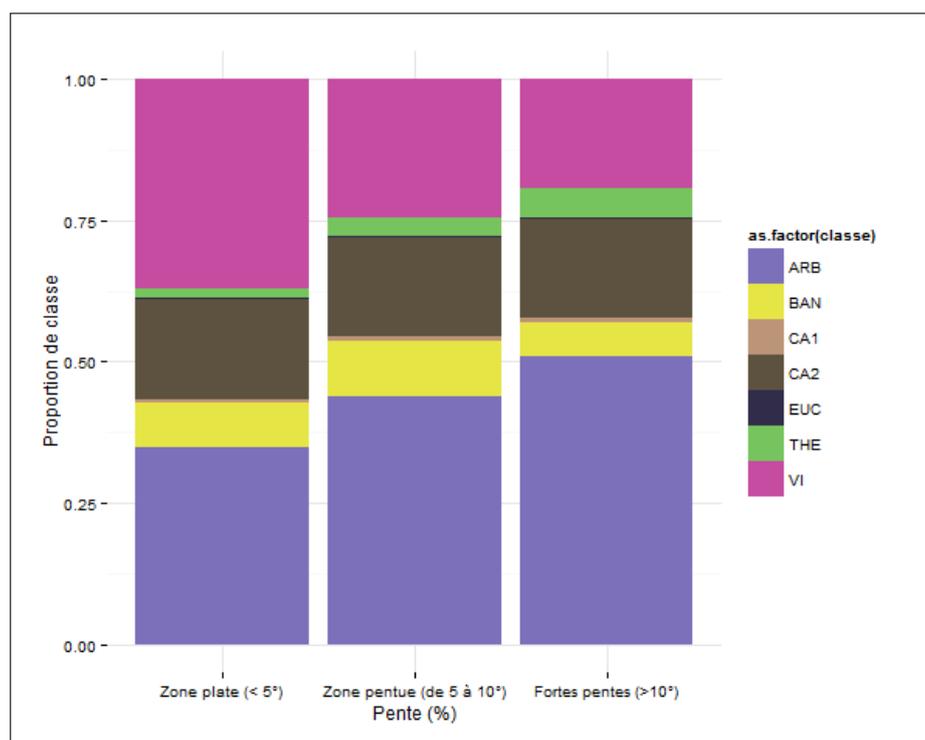


FIGURE 6.12 – Répartition des classes le long du gradient de pente

On remarque ici l'importance croissante des cultures arborées avec la pente, inversement corrélées avec celle du vivrier que l'on rencontre en fond de vallée, là où les pentes sont faibles. Le thé semble de même être majoritairement présent dans des zones pentues.

6.3 Perspectives d'utilisation pour les agronomes

Nous avons pu calculer quelques statistiques de base sur les données que nous possédons. Cependant, au vu des problèmes inhérents à la classification et au manque de temps pour continuer les analyses, des études plus poussées des résultats n'ont pas été réalisées. Ces traitements sur les données et leur intérêt potentiel sont listés ci-dessous :

- Il serait possible de caractériser la répartition des classes le long des reliefs locaux, en introduisant une notion d'ordre au sein de la séquence. Il serait ainsi possible d'établir, pour différentes zones de Murang'a, les typologies d'installation des exploitants sur les pentes qu'ils possèdent. De la même manière, à l'aide de la classification des zones non végétales, il serait possible d'étudier les relations de proximité entre chaque classe et les bâtiments des exploitations.
- Il serait possible de reprendre les données du MNH pour réaliser une classification du sursol. Cela permettrait de différencier plusieurs types de végétation haute tels que les arbres isolés, les haies d'arbres, ou les massifs forestiers. Ces différentes entités sont importantes pour la compréhension des parcelles d'agroforesterie et des stratégies de production de leurs cultivateurs.
- Enfin, nous pouvons procéder à une mesure d'autocorrélation spatiale en utilisant par exemple l'indice de Moran. Cet indice tient compte des corrélations entre les mesures géographiquement voisines d'un phénomène. Cela permet ainsi de vérifier s'il y a indépendance ou non dans la répartition géographique des classes, les valeurs de pente et de hauteur du sursol, point clé pour la compréhension de la structure de Murang'a.

Conclusion

Ce travail de 6 mois visait à évaluer la pertinence de l'achat de triplets stéréoscopiques Pléiades pour les travaux de cartographie et de caractérisation en agroforesterie. Il apparaît que les produits 3D en découlant permettent une légère amélioration des chaînes de traitement de classification, toutefois avec une significativité modérée. La chaîne en elle-même a cependant des difficultés à assurer une classification robuste sur l'ensemble des terres complexes de Murang'a. Les résultats pourraient cependant être améliorés à l'aide d'un meilleur échantillonnage initial des classes ou d'une segmentation plus fidèle aux contours naturels des parcelles. L'hétérogénéité et la complexité des systèmes de culture rendent toutefois la mise en valeur de certaines classes d'agroforesterie quasi impossibles pour les données Pléiades qui trouve ici leurs limites fondamentales.

Des questions de recherche fondamentales ont pu émerger durant ce stage, ces problématiques pourraient permettre à l'avenir de mieux comprendre comment améliorer les différentes étapes techniques aboutissant à la donnée 3D, et donc leur qualité. Sachant que la tri stéréoscopie demande le triple de l'investissement financier d'une acquisition classique, il est difficile à l'heure actuelle d'envisager des applications concrètes. La qualité de ces données 3D est de même très logiquement de qualité inférieure à celles que l'on génère grâce au LIDAR ou même aux ULM/drones qui se révèlent plus aptes à caractériser de manière fine la structure du couvert. Des sous-produits comme un MNT à très haute résolution peuvent être remobilisés pour d'autres applications mais leur validité est encore à prouver.

De manière générale, à l'heure où les applications commerciales de drones pour l'agriculture se multiplient, la branche stéréo par satellite semble être logiquement délaissée en raison de son manque de précision et des difficultés techniques et théoriques qui résident encore dans la création des produits. Elle peut cependant intéresser les professionnels souhaitant obtenir sans contraintes de terrain une information nouvelle sur les couverts arborés de zones à la superficie trop importante pour être balayées par de l'imagerie drone ou du LIDAR.

L'utilisation plus générale de la donnée Pléiades aura tout de même ici permis d'illustrer l'apport de la télédétection pour mieux comprendre la région. La cartographie obtenue permet de mieux visualiser la répartition et la distribution des systèmes de culture à base de caféiers et leur proportion par rapport aux autres systèmes de culture. Des statistiques géo spatiales simples portant sur l'occupation du sol peuvent alors être réalisées sur une grande superficie sans avoir recours au terrain, dont les interprétations sont utiles aux agronomes travaillant sur la région.

- Australia Geoscience. 1 second SRTM Derived Products User Guide. (October), 2011.
- Karim Barkaoui. Effet des systèmes de culture agroforestiers paysans sur l'incidence des maladies cryptogamiques (Coffee Berry Disease, Coffee Leaf Rust) et sur la production de café dans la région de Murang'a au Kenya. Technical report, Montpellier Supagro, 2010.
- Leo Breiman. Random Forests. *Machine Learning*, pages 1–33, 2001. ISSN 08856125. doi : 10.1023/A:1010933404324.
- Chao Chen, Andy Liaw, and Leo Breiman. Using random forest to learn imbalanced data. *University of California, Berkeley*, (1999) :1–12, 2004.
- Cirad. Third Interim Narrative Report. Technical Report March, 2014.
- Paul R Cooper, Daniel E Friedman, and Scott A Wood Macdonald. The automatic generation of digital terrain models from satellite images by stereo. *Acta Astronautica*, 15(3) :171–180, 1987.
- Gauthier Crepy. Effet des pratiques agricoles sur la fertilité du sol et les productions végétales dans les systèmes agroforestiers à base de caféiers dans la région centrale du Kenya. Technical report, AgroParisTech, 2014.
- Carlo De Franchis, Gabriele Facciolo, Enric Meinhardt, Julien Michel, and Jean-michel Morel. s2p : An automatic stereo pipeline for Pléiades A part of Toulouse reconstructed with s2p from a tristereo dataset. *IEEE Transactions on*, 30(3) :328–341, 2013. URL <http://dev.ipol.im/~carlo/s2p/>.
- Abdolhamid Dehvari and Richard John Heck. Removing non-ground points from automated photo-based DEM and evaluation of its accuracy with LiDAR DEM. *Computers and Geosciences*, 43 :108–117, 2012. ISSN 00983004. doi : 10.1016/j.cageo.2012.02.013. URL <http://dx.doi.org/10.1016/j.cageo.2012.02.013>.
- Thanh-nghi Do. iNterprétation des résultats de svm.
- Stéphane Dupuy, Camille Lelong, and Stéphane Marty. Potential of Pléiades mono-and tri-stereoscopic images for the agricultural mapping in Mayotte. 2014.
- Arnaud Durand, Julien Michel, Carlo de Franchis, Bernard Allenbach, and Alain Giros. Qualitative assessment of four DSM generation approaches using Pléiades-HR data. *33th EARSeL Symposium*, pages 499–510, 2013.
- A Gebejes and R Huertas. Texture Characterization based on Grey-Level Co-occurrence Matrix. 2013.
- D. Giribabu, S. Srinivasa Rao, and Y. V N Krishna Murthy. Improving Cartosat-1 DEM accuracy using synthetic stereo pair and triplet. *ISPRS Journal of Photogrammetry and Remote Sensing*, 77(March 2012) :31–43, 2013. ISSN 09242716. doi : 10.1016/j.isprsjprs.2012.12.005. URL <http://dx.doi.org/10.1016/j.isprsjprs.2012.12.005>.
- Valentin Greugny. Utilisation d'images Pléiades tri - stéréoscopiques pour la production d'un modèle numérique de surface. Technical report, Université Montpellier 2, 2014.

- a W Gruen. Adaptive least squares correlation : a powerful image matching technique. *South African Journal of Photogrammetry, Remote Sensing and Cartography*, 14(3) :175–187, 1985. URL http://www.idb.arch.ethz.ch/files/alsm_awgruen.pdf.
- Alexandros Karatzoglou, David Meyer, and Kurt Hornik. Support Vector Machines in R. *Journal of Statistical Software*, 15(9) :28, 2006. ISSN 1548-7660. URL <http://www.jstatsoft.org/v15/i09/paper>.
- David G Lowe. Distinctive Image Features from Scale-Invariant Keypoints. pages 1–28, 2004.
- Wenjian Ni, Guoqing Sun, Kenneth Jon Ranson, Yong Pang, Zhiyu Zhang, and Wei Yao. Extraction of ground surface elevation from ZY-3 winter stereo imagery over deciduous forested areas. *Remote Sensing of Environment*, 2015. ISSN 00344257. doi : 10.1016/j.rse.2014.12.007.
- R. Perko, H. Raggam, K. H. Gutjahr, and M. Schardt. ADVANCED DTM GENERATION FROM VERY HIGH RESOLUTION SATELLITE STEREO IMAGES. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2015. ISSN 2194-9050. doi : 10.5194/isprsannals-II-3-W4-165-2015.
- D. Poli, F. Remondino, E. Angiuli, and G. Agugiaro. Radiometric and geometric evaluation of GeoEye-1, WorldView-2 and Pleiades-1A stereo images for 3D information extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 100 :35–47, 2014. ISSN 09242716. doi : 10.1016/j.isprsjprs.2014.04.007. URL <http://dx.doi.org/10.1016/j.isprsjprs.2014.04.007>.
- E Rodriguez, CS Morris, and JE Belz. An assessment of the SRTM topographic products. *Photogrammetric Engineering and Remote Sensing*, 2006. doi : 0099-1112/06/7203\$0249/\$3.00/0.
- J. R. Rosell and R. Sanz. A review of methods and applications of the geometric characterization of tree crops in agricultural activities, 2012. ISSN 01681699.
- Clélia Roucoux. La caféiculture au Kenya entre recul et résilience : le cas du comte de Muranga. Technical report, Montpellier SupAgro, 2014.
- Nicole Sibelet, Mathilde Montzieux, Costa Rica, and Costa Rica. Les facteurs de résilience de la caféiculture au Kenya : de la sécurisation alimentaire à la retraite. 21, 2012.
- R. Simard. Digital stereo processing of satellite image data, 1987. ISSN 02731177.
- Kenichi Tatsumi, Yosuke Yamashiki, Miguel Angel Canales Torres, and Cayo Leonidas Ramos Taïpe. Crop classification of upland fields using Random forest of time-series Landsat 7 ETM+ data. *Computers and Electronics in Agriculture*, 115 :171–179, 2015. ISSN 01681699. doi : 10.1016/j.compag.2015.05.001. URL <http://linkinghub.elsevier.com/retrieve/pii/S0168169915001234>.
- Claude Toko. Les systèmes agroforestiers à base de café au Kenya : Dynamique de diversification et d ’ amélioration de la sécurité alimentaire et des conditions de vie. Technical report, Montpellier SupAgro, 2013.
- Xiaohua Tong, Shijie Liu, and Qihao Weng. Bias-corrected rational polynomial coefficients for high accuracy geo-positioning of QuickBird stereo imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2010. ISSN 09242716. doi : 10.1016/j.isprsjprs.2009.12.004.

- T Toutin. DTM generation from Ikonos in-track stereo images using a 3D physical model. *Photogrammetric Engineering and Remote Sensing*, 2004. ISSN 0099-1112. doi : 10.14358/PERS.70.6.695.
- Th Toutin, C. V. Schmitt, and H. Wang. Impact of no GCP on elevation extraction from WorldView stereo data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012. ISSN 09242716. doi : 10.1016/j.isprsjprs.2012.05.009.
- Philippe Vaast, Benoit Bertrand, Jean Jacques Perriot, Bernard Guyot, and Michel Génard. Fruit thinning and shade improve bean characteristics and beverage quality of coffee (*Coffea arabica* L.) under optimal conditions. *Journal of the Science of Food and Agriculture*, 86(2) : 197–204, 2006. ISSN 00225142. doi : 10.1002/jsfa.2338.
- Mi Wang, Fen Hu, and Jonathan Li. Epipolar resampling of linear pushbroom satellite imagery by a new epipolarity model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011. ISSN 09242716. doi : 10.1016/j.isprsjprs.2011.01.002.
- David H. Wolpert. The Existence of A Priori Distinctions Between Learning Algorithms. *Neural Computation*, 8(7) :1391–1420, 1996. ISSN 0899-7667. doi : 10.1162/neco.1996.8.7.1391.

Table des annexes

A	Logiciels utilisés durant la mission	52
B	Description des scripts utilisés	53
C	Caractéristiques des acquisitions Pléiades	54
D	Topographie de la zone	55
E	Corrections radiométriques Pléiades	56
F	Détails de l'orthorectification du triplet Pléiades	57
G	Workflow de la stéréoscopie sous ERDAS Imagine	58
H	Résultats détaillés des tests sur ERDAS Imagine	59
I	Représentation 3D du MNS et de l'image Satellite	64
J	Reconnaissance d'éléments typiques de sursol	65
K	Techniques de création du MNH à partir du MNS	66
L	Autres sous-produits	67
M	Tableau récapitulatif des arbres mesurés sur le terrain	68
N	Jeu d'apprentissage	70
O	Création des indices d'Haralick	71
P	Présentation des attributs utilisés pour la classification	72
Q	Script R utilisé pour la classification	74
R	Séparation des classes par les indices de texture	76
S	Analyse ACP des données d'apprentissage	77
T	Ruleset Ecognition	80
U	Fonctionnement des algorithmes SVM et Random Forest	81
V	Planches de classification sur les 5 zones	82
W	Importance des variables du Random Forest pour chaque classe	86
X	Cartographie finale de l'occupation du sol	87
Y	Incertitudes sur les résultats	88

A

Logiciels utilisés durant la mission

Logiciels gratuits

Quantum GIS (QGIS)

Visualisation de rasters et de shapefiles. Création de cartes et d'atlas. Edition de données spatiales (table attributaire, bandmath, fusion, rasterisation. . .) Utilisation de lignes de commande GDAL

R (avec l'EDI R Studio)

Scripts de traitement statistique ou de traitement spatial non couverts par Qgis/Gdal.

Orfeo Tool Box (avec GUI en Qt Monteverdi 2)

Traitement radiométrique des images Pléiades

Logiciels payants

E-Cognition

Segmentation, classification, export de statistiques spatiales

LAStools

Visualisation de nuages de points 3D, découpe

ENVI

Pansharpening des images Pléiades (Gram Schmidt), Création d'indices de textures

ERDAS Imagine

Stéréoscopie. Création d'une mosaïque de rasters

B

Description des scripts utilisés

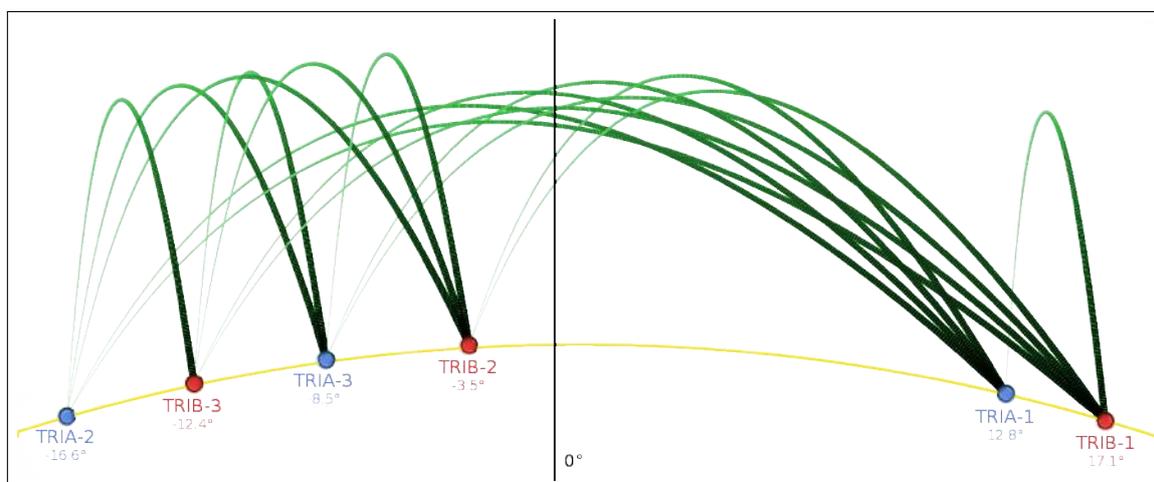
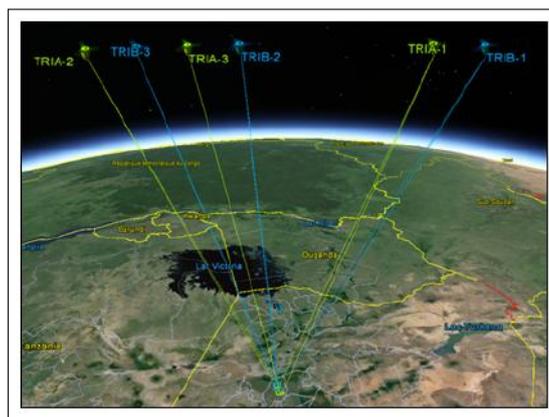
ACP.R	ACP et représentation des résultats sur le jeu d'apprentissage
Extraction_raster_polys.R	Extraction des valeurs moyennes d'un ou plusieurs raster sous un shapefile
Classification_segments.R	Implémentation de Random Forest et de SVM pour la classification
Densite_raster.R	Création d'une carte de densité à partir d'un raster binaire
Hauteur_arbres.R	Comparaison des arbres du MNS avec les mesures terrain
Transect_Zones.R	Coupe du raster SRTM pour créer un profil d'élévation
Verif_qualite_ortho.R	Précision du calage des images Pléiades à l'aide de points de test répartis
OTBstereo.bat	Utilisation du module stereo sous OTB (non fonctionnel)
sommets2shape.py	Transforme une liste de sommets (coordonnées) labellisés en un shapefile de polygones

C

Caractéristiques des acquisitions Pléiades

Deux acquisitions Pléiades dites « stéréo » (acquisition d'une même zone sous des angles différents) ont été programmées pour le 4 Janvier 2015. Leurs caractéristiques sont présentées dans le tableau suivant.

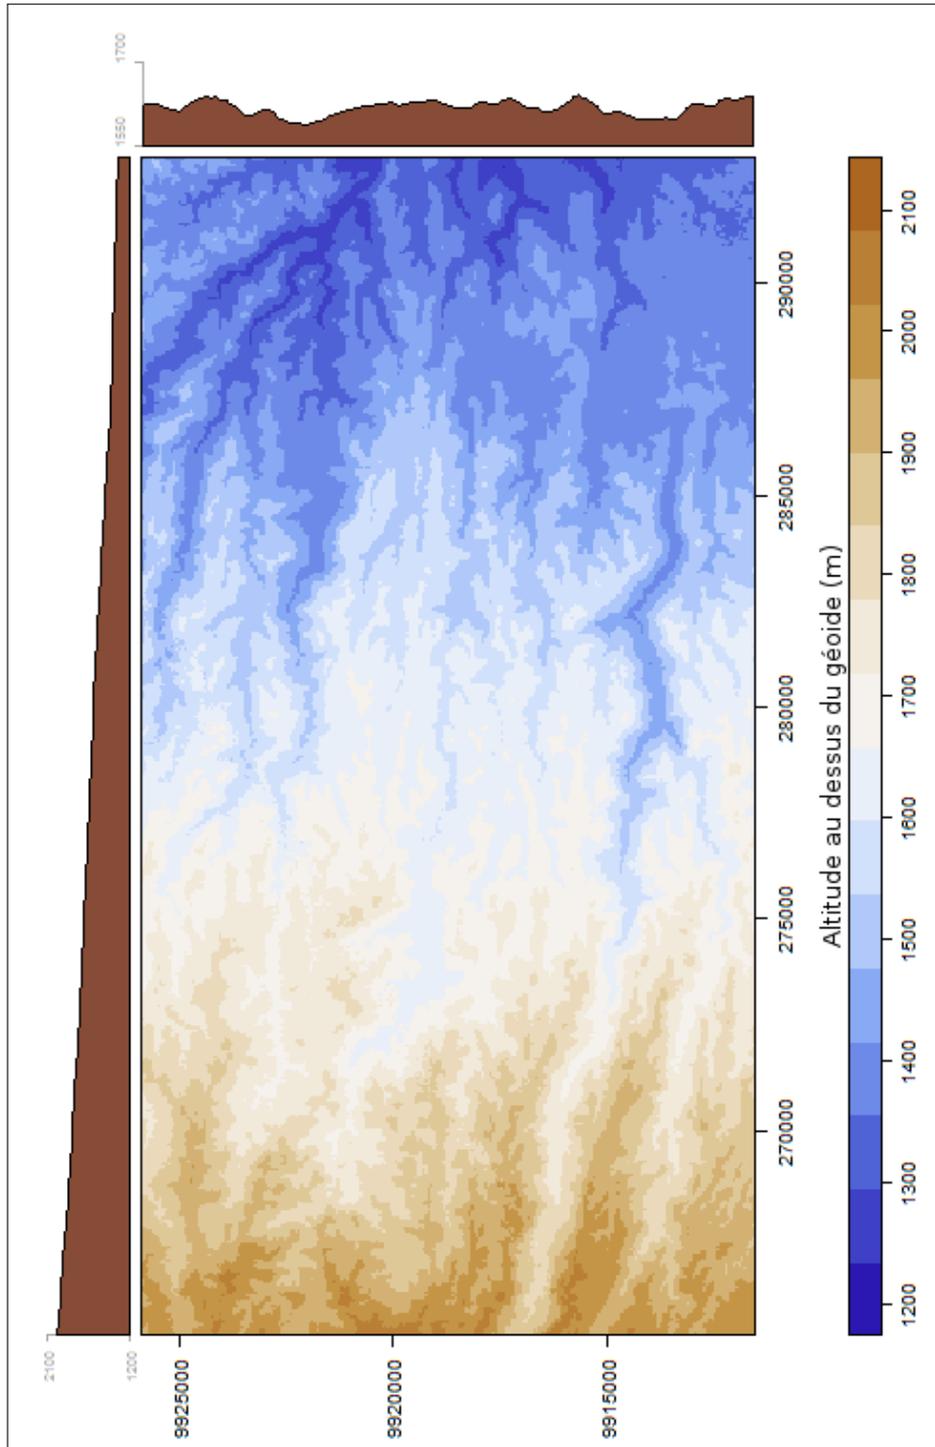
Date	Heure	Triplet	Angle de vue (°)
04/01/2015	07 :59 :00	1	12.9
	07 :59 :54	1	-16.7
	07 :59 :38	1	-8.2
	07 :59 :52	2	17.1
	07 :59 :30	2	-3.5
	07 :59 :46	2	12.4



D

Topographie de la zone

Issu des données SRTM à 30m de résolution. Coordonnées projetées UTM zone 37S. Transects pris au « milieu » de la zone, en longitude et en latitude.



Soit une bande désignée par un indice λ :

Passage de la valeur numérique à la luminance

$$Luminance_{\lambda} = \frac{DC}{GAIN_{\lambda}} + BIAS_{\lambda}$$

Les valeurs de gain et d'offset (exprimées en W/sr) sont normalement mentionnées dans les métadonnées de l'image

Passage de la luminance à la réflectance TOA

$$Reflectance_{\lambda} = \frac{\pi * Luminance_{\lambda}}{ESUN_{\lambda} * \sin \theta}$$

Avec :

$$Luminance_{\lambda} = \text{Luminance en } W/(m^2 \cdot sr \cdot \mu m)$$

d = Distance de la terre au soleil (UA). Valeur très proche de 1

$$ESUN_{\lambda} = \text{Irradiance solaire en } W/(m^2 \cdot \mu m)$$

$\theta = \text{Angle de vue}$

La réflectance est comprise entre 0 et 1, elle représente la fraction solaire réfléchiée par une surface, pour une bande donnée.

Passage de la réflectance TOA à la réflectance Top Of Canopy (TOC)

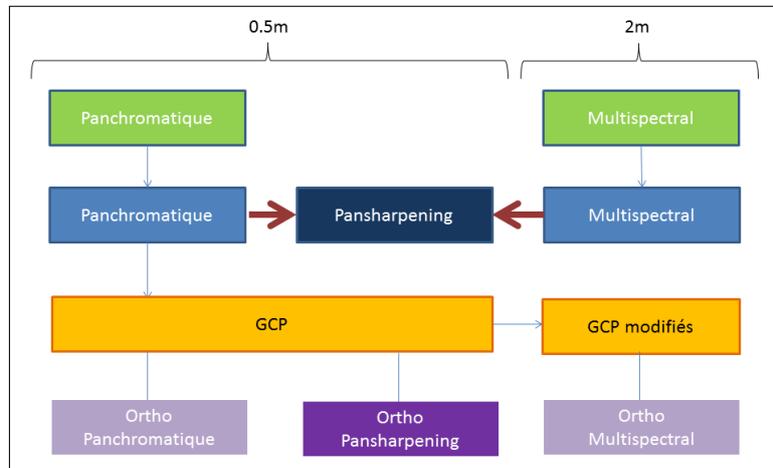
On peut éliminer enfin les divers effets liés à l'atmosphère tels que la pression atmosphérique, la composition en aérosols et la quantité d'ozone. Cela influence particulièrement les bandes dont la longueur d'onde est située dans le bleu.

Dans notre cas, le choix a été fait de s'arrêter à la réflectance TOA en raison du manque de données atmosphériques permettant de prendre ces paramètres en compte.

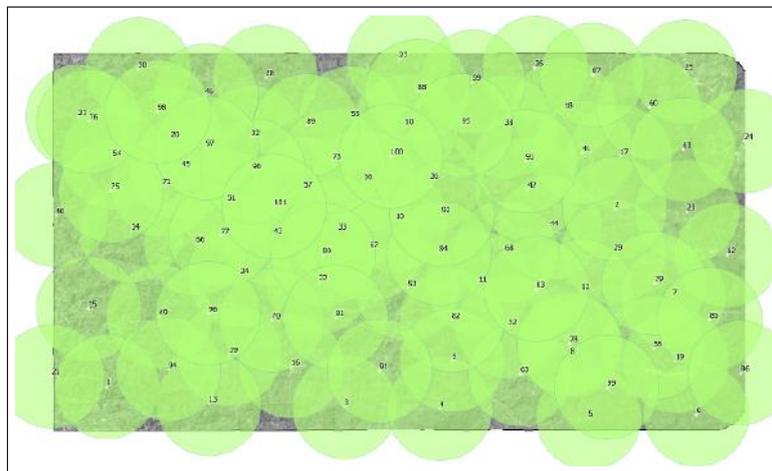
F

Détails de l'orthorectification du triplet Pléiades

Procédé d'ortho rectification adopté sur ERDAS IMAGINE



Répartition des GCP utilisés avec un rayon de 2km

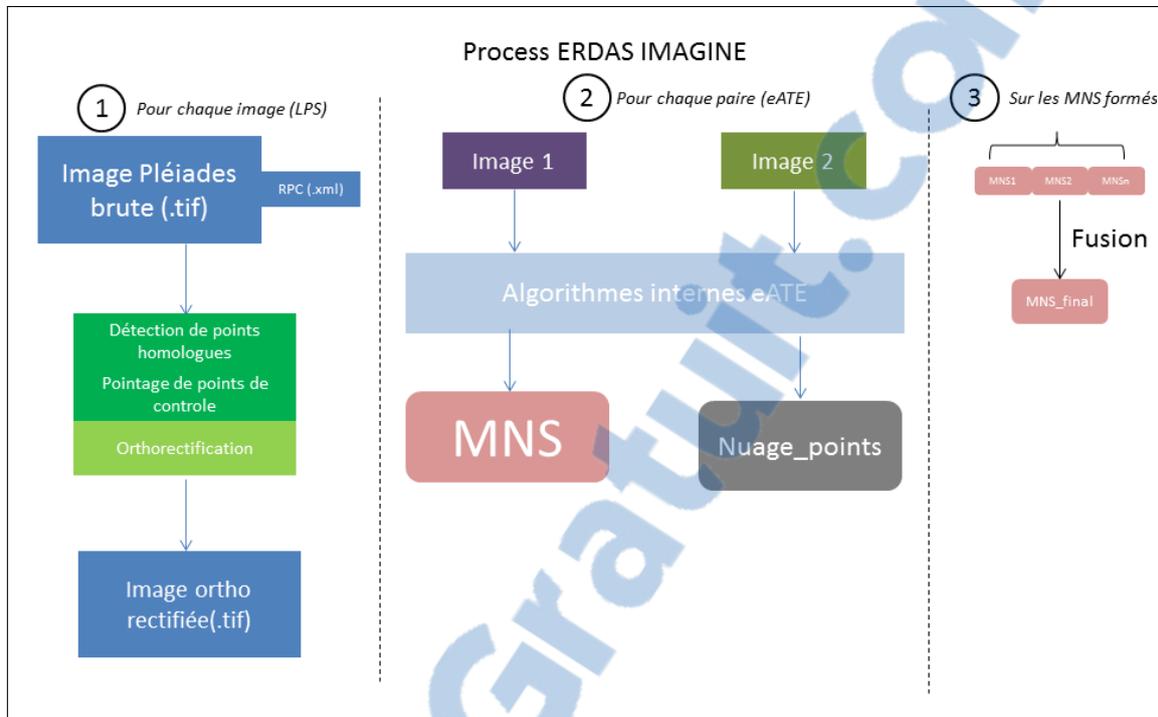


Evolution de la RMSE annoncée par ERDAS avec la répartition des GCP et des TP

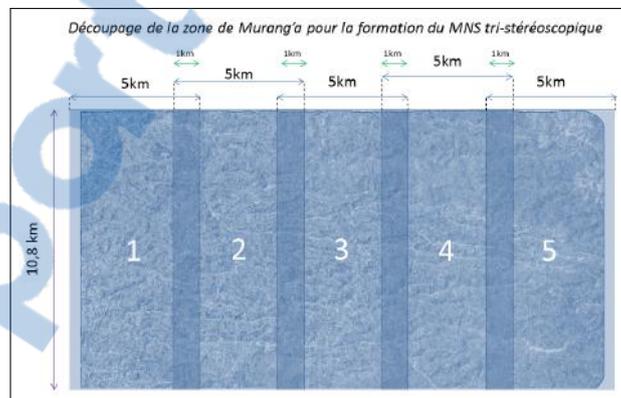
Nombre de GCP	41	41	0	20	10	5
Nombre de TP	51	0	51	25	12	6
RMSE (m)	0.67	0.29	0.74	0.32	0.23	0.21

G

Workflow de la stéréoscopie sous ERDAS Imagine



Application des algorithmes à la région entière

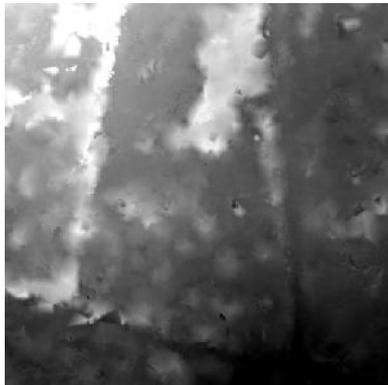


Zone de test

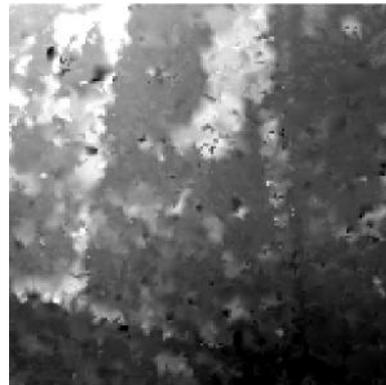


I – Application des meilleurs paramètres pour un autre cadre

Paramètres de base



Paramètres rapport V.GREUGNY

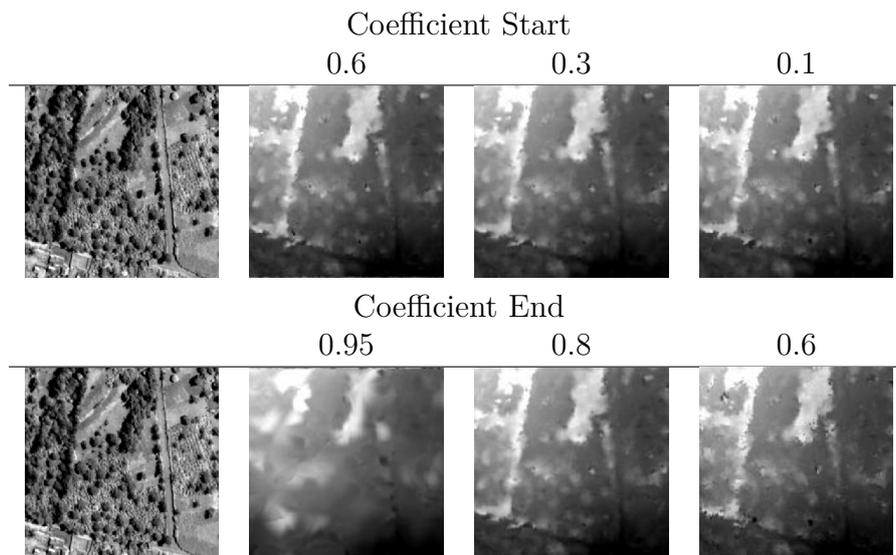


On remarque de suite que le MNS obtenu avec les paramètres de base semble de meilleure qualité. Cela illustre une des principales difficultés avec la stéréoscopie : la qualité du produit en sortie dépend fortement de la zone traitée. Les paramètres recommandés ont été établis sur une zone de Mayotte bien différente de la zone kenyane que l'on étudie. Il n'existe donc pas de paramètres optimaux et universels pour la qualité du MNS.

II – « Coefficient Start » et « Coefficient End »

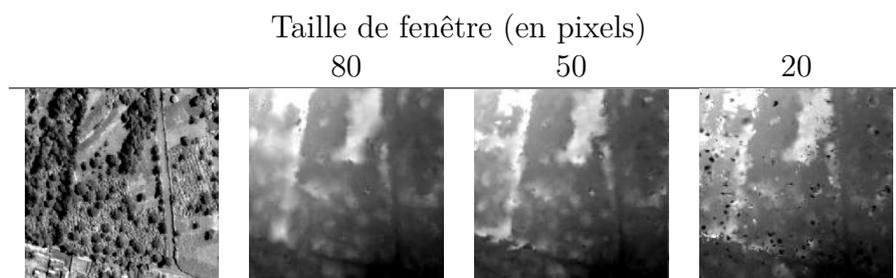
Ces deux paramètres sont mobilisés dans l'algorithme de corrélation. Le coefficient de départ correspond à un seuil d'élimination utilisé sur le niveau de pyramide le plus élevé. Le coefficient de fin est alors utilisé sur le dernier niveau de pyramide.

Faire tendre le coefficient de fin vers 1 aggrave considérablement la qualité du produit. Le diminuer rend le résultat plus net et granuleux mais empêche la distinction de certains éléments. Le coefficient de début semble avoir moins d'importance, sa variation entraîne des modifications difficilement perceptibles à l'œil.



III – Taille de fenêtre

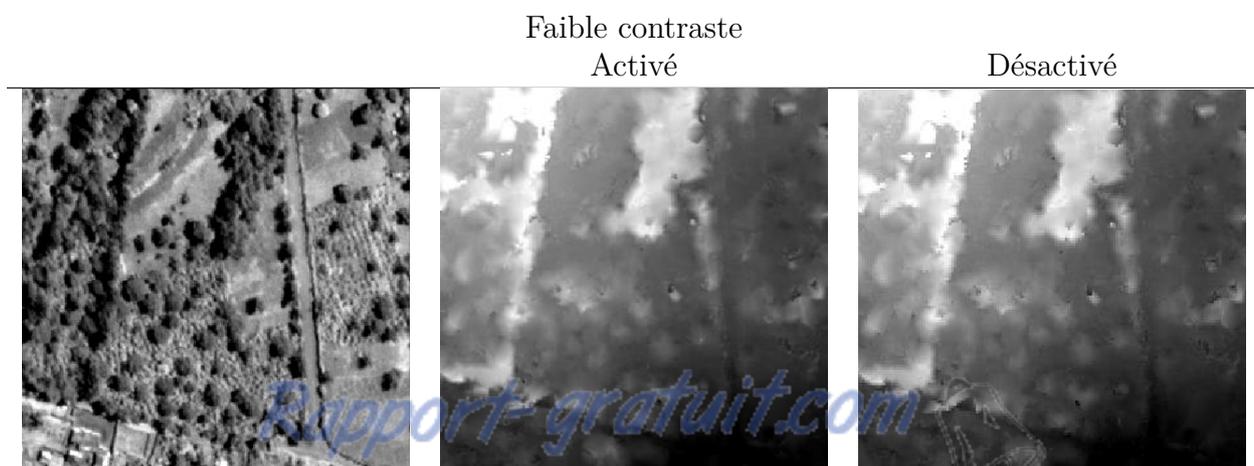
La taille de fenêtre est la taille de la zone de recherche autour de chaque point pour l'interpoler durant la création du MNS



Sans surprise, une taille de fenêtre trop faible entraîne des difficultés à trouver des points pour l'interpolation. Cela se voit par l'apparition de taches noires n'ayant pas pu être interpolées. A contrario, utiliser une taille de fenêtre trop grande a ici un effet lissant.

IV – Option faible contraste

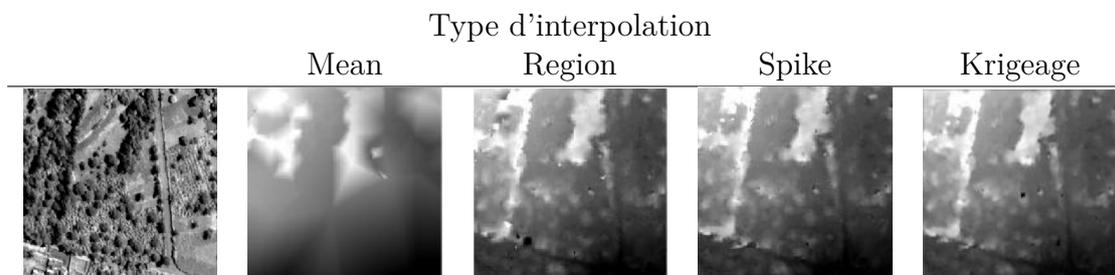
L'option « Low Contrast » permet de forcer des correspondances dans certaines zones à faible contraste. Cette option semble adaptée aux zones forestières.



L'utilisation ou non de cette option ne change rien (du moins pas de manière perceptible) aux résultats.

V – Type d'interpolation

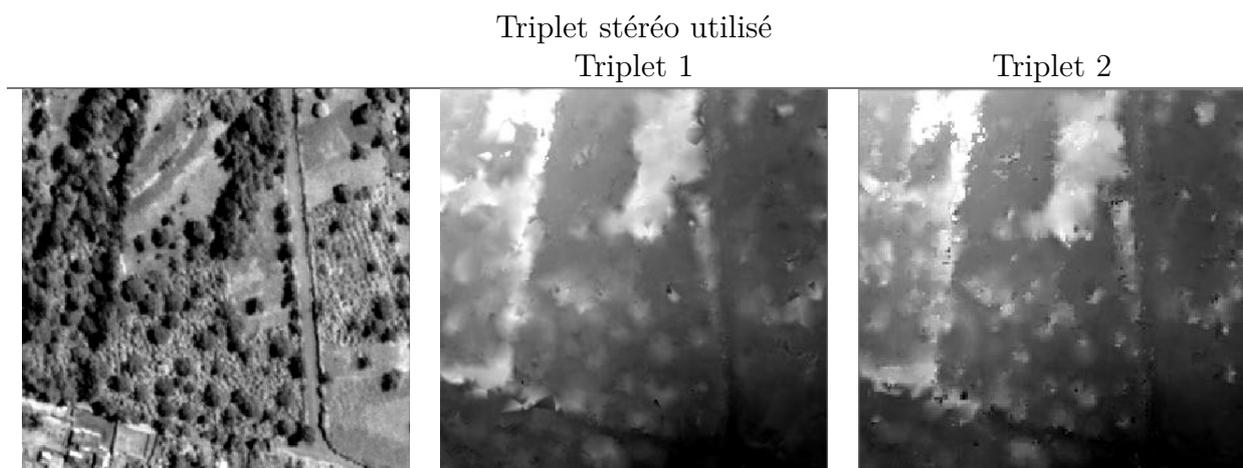
Ce paramètre définit l'algorithme d'interpolation utilisé pour passer du nuage de points au MNS. L'algorithme d'ERDAS par défaut est Spike mais il est possible de choisir l'option Mean. Un 4ème type d'interpolation a été testé : le krigeage du nuage de points sur un logiciel externe : ArcGIS.



On peut très clairement éliminer l'option l'algorithme Mean. La différence entre Region et Spike n'est cependant pas évidente. On remarque cependant une présence plus élevée d'artefacts dans la méthode Region. Quant à l'interpolation par krigeage, celle-ci donne globalement de bons résultats mais son application sur de grandes zones n'est pas envisageable en raison du temps de calcul excessif (1 jour pour traiter le nuage de point sur une surface d'1km²) . La stratégie de corrélation (de base Normalised Cross Correlation) n'a malheureusement pas pu être modifiée en raison du plantage du programme lorsqu'une autre stratégie était choisie (Sum of Squared Difference).

VI– Stéréoscopie à 3 ou plus image

Passons maintenant à la tri-stéréoscopie, c'est-à-dire la stéréoscopie utilisant 3 images, que l'on peut décomposer en 3 paires. Les MNS issus de plusieurs types de triplets ont été générés, leur qualité est variable comme le montre la figure suivante :



Le nombre d'images peut être augmenté, nous présentons ici des exemples d'utilisation possible de la stéréoscopie à 4 images (12 paires possibles) , à 5 images et à 6 images.

L'utilisation de plus de 3 images simultanées a tendance à rendre les contours plus nets mais apporte en contrepartie du bruit. Cela ne permet cependant pas de distinguer plus d'éléments que pour la tri-stéréoscopie.

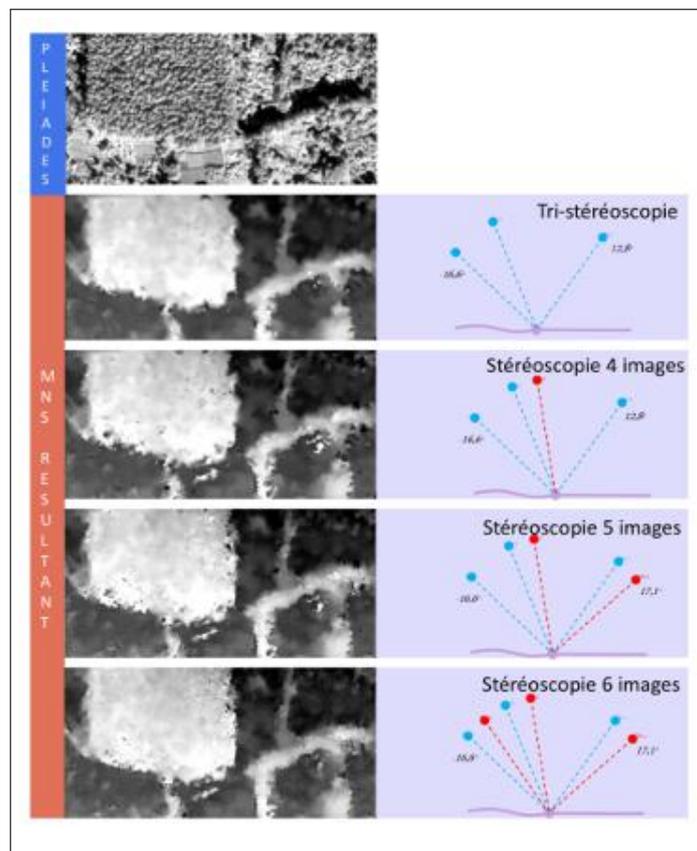
Tests préliminaire sur la stéréoscopie à plus de 3 images

Test de stéréoscopie à 6 images



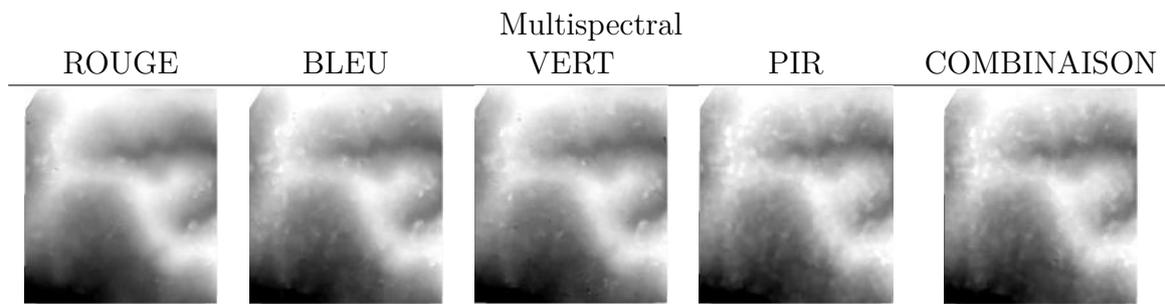
Les résultats sont contrastés. Le MNS semble légèrement plus fin mais il ne permet pas de discriminer plus d'objets et possède une texture plus granuleuse qui pourrait être gênante pour l'extraction d'informations.

Tests préalables en faisant varier le nombre d'images



VII- Utilisation des images multispectrales haute résolution

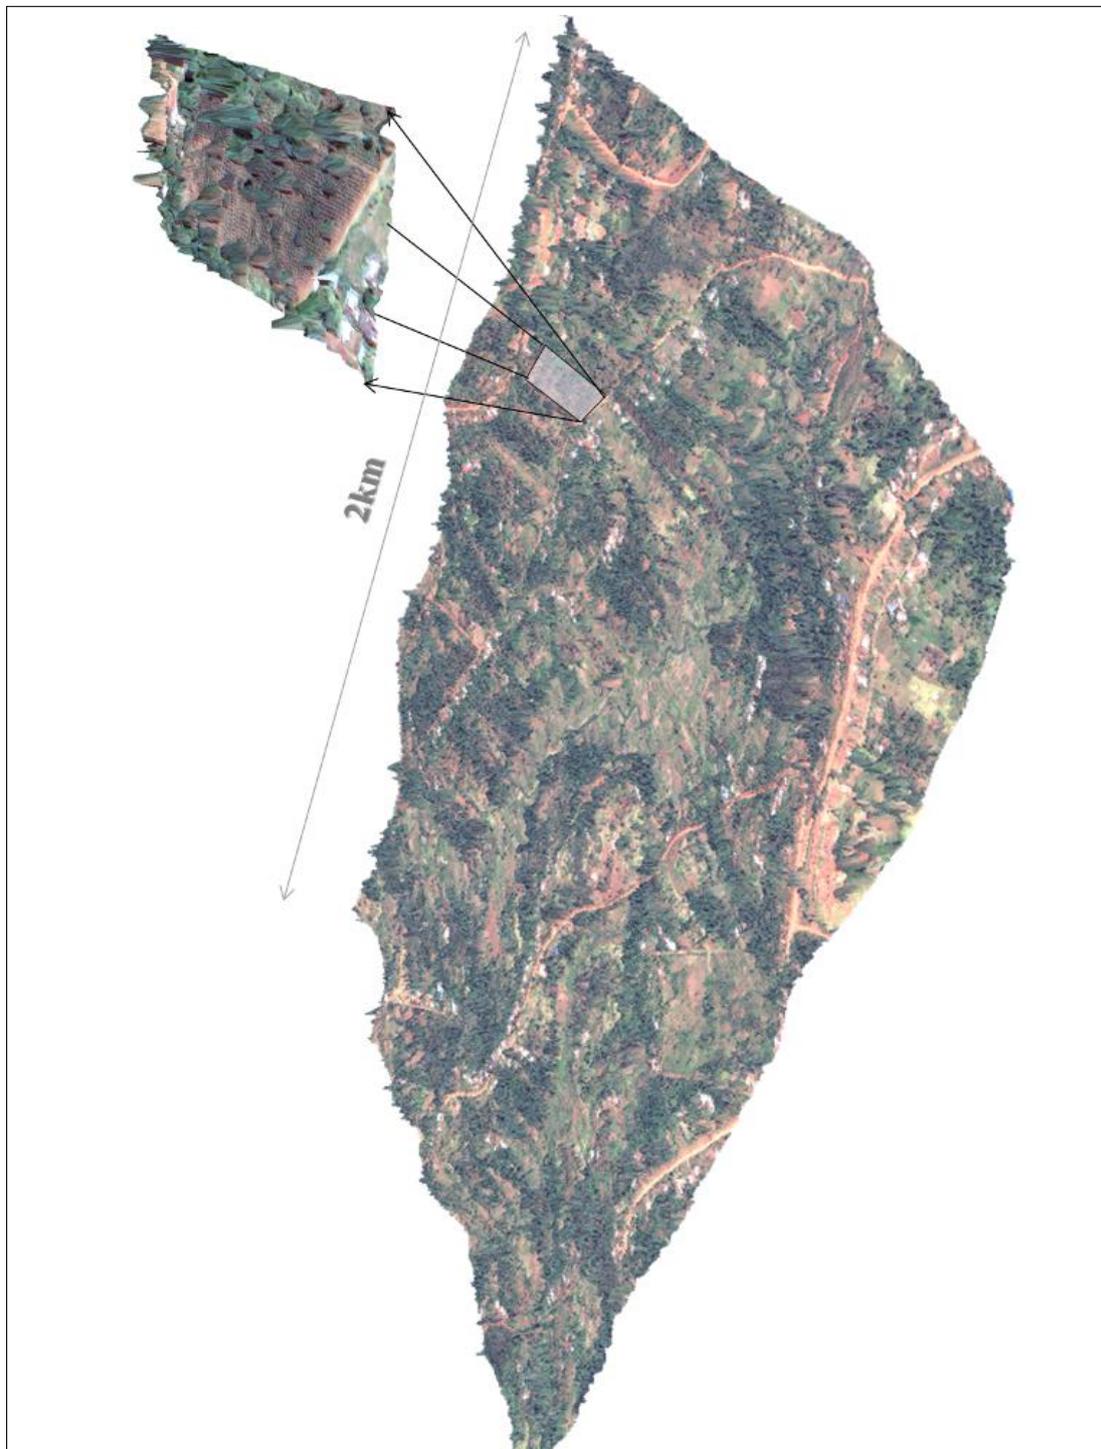
Les images multi spectrales sont de résolution moindre mais elles apportent aussi une information radiométrique nouvelle. Le traitement des images multispectrales est testé ici, de manière individuelle ou en combinant les 4 bandes.



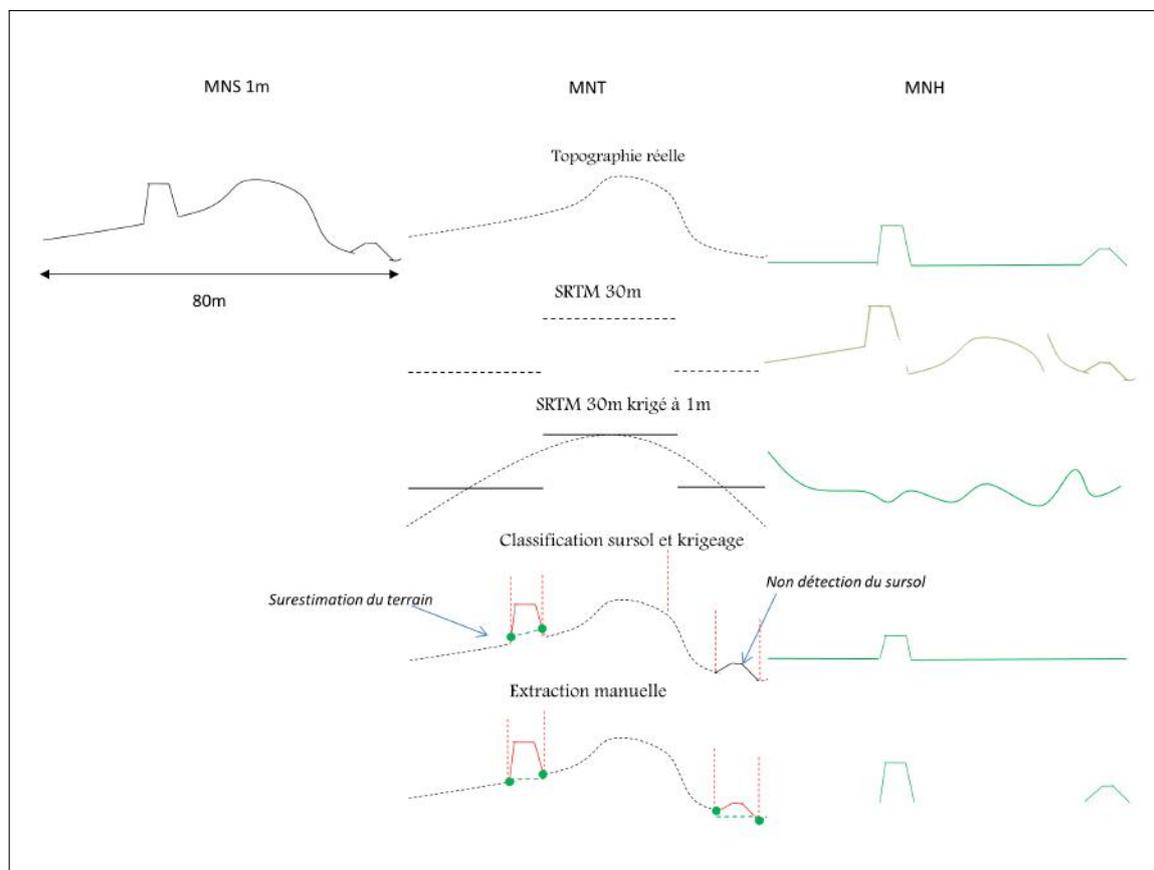
L'infrarouge est la bande permettant la restitution de détails avec le plus de finesse. Le MNS en sortie reste cependant grossier, preuve que l'utilisation de l'image panchromatique à 50cm de résolution n'est pas superflue, même pour la distinction d'objets visibles.

Représentation 3D du MNS et de l'image Satellite

A l'aide du module Arcscene d'ArcGIS, il est possible de draper l'image Pléiades sur le modèle numérique de surface obtenu. On obtient alors une vue en 3D de la zone pouvant être visuellement plus frappante que les deux couches consultées séparément.



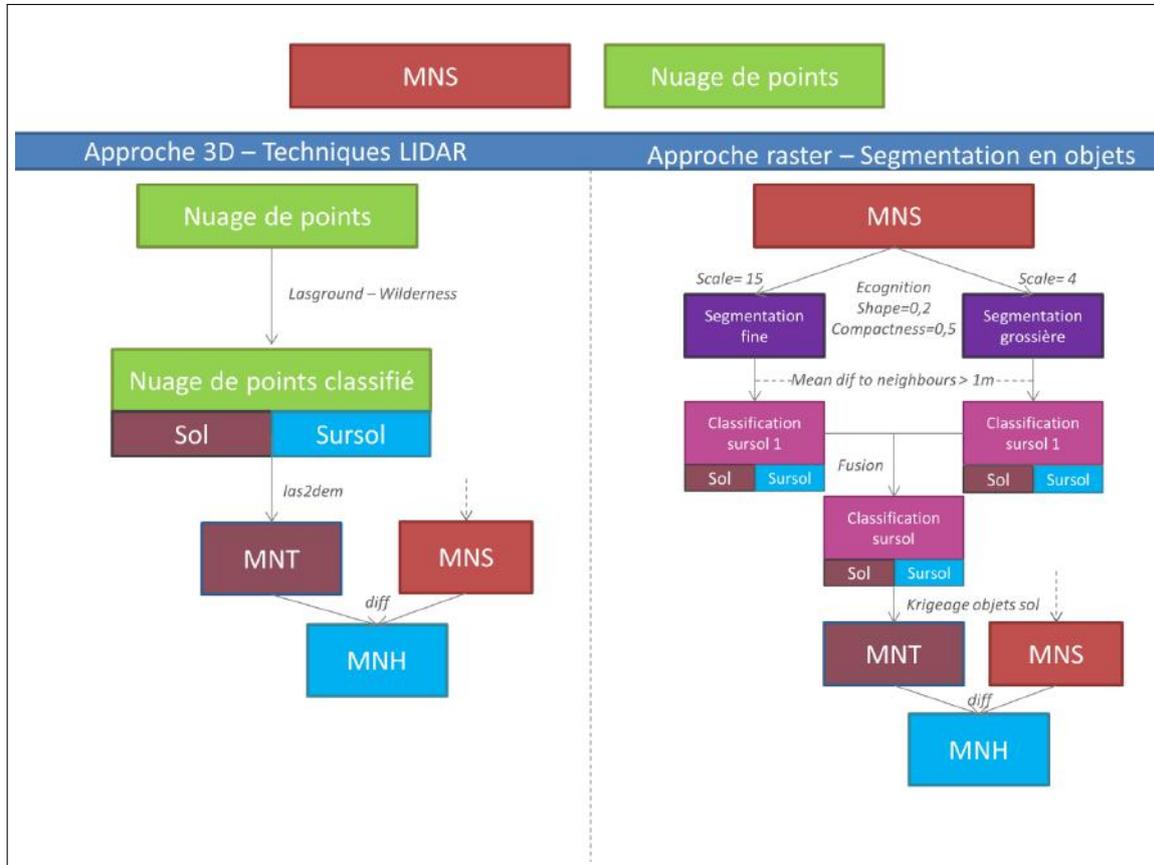
Techniques d'extraction de la hauteur d'un arbre en particulier à partir du MNS



Détail des méthodes, de haut en bas :

- Soustraction du MNT théorique (n'existant pas physiquement) au MNS afin d'obtenir le MNH optimal
- Soustraction du MNT SRTM à 30m. Sa résolution peu enlevée provoquera des erreurs d'autant plus fortes que la différence avec l'altitude réelle en un point est élevée
- Soustraction du MNT krigé à 1m. L'interpolation permet de lisser le MNT et d'obtenir des différences moins importantes. Cependant il ne tient pas compte des irrégularités de l'altitude au sein de chaque pixel.
- Détection du sursol. L'opération consiste à classer les pixels de sursol, à interpoler les « trous » dans le raster non-sursol, puis à soustraire le MNT ainsi formé avec le MNS. Cette opération utilise une seule source de donnée et limite donc les erreurs sur le MNH
- Extraction manuelle. Consiste en la délimitation manuelle des objets pour extraire individuellement la hauteur des couronnes. On prendra comme altitude du sol la moyenne de 4 points autour de l'arbre et l'altitude de l'arbre comme la valeur maximale des pixels de l'arbre.

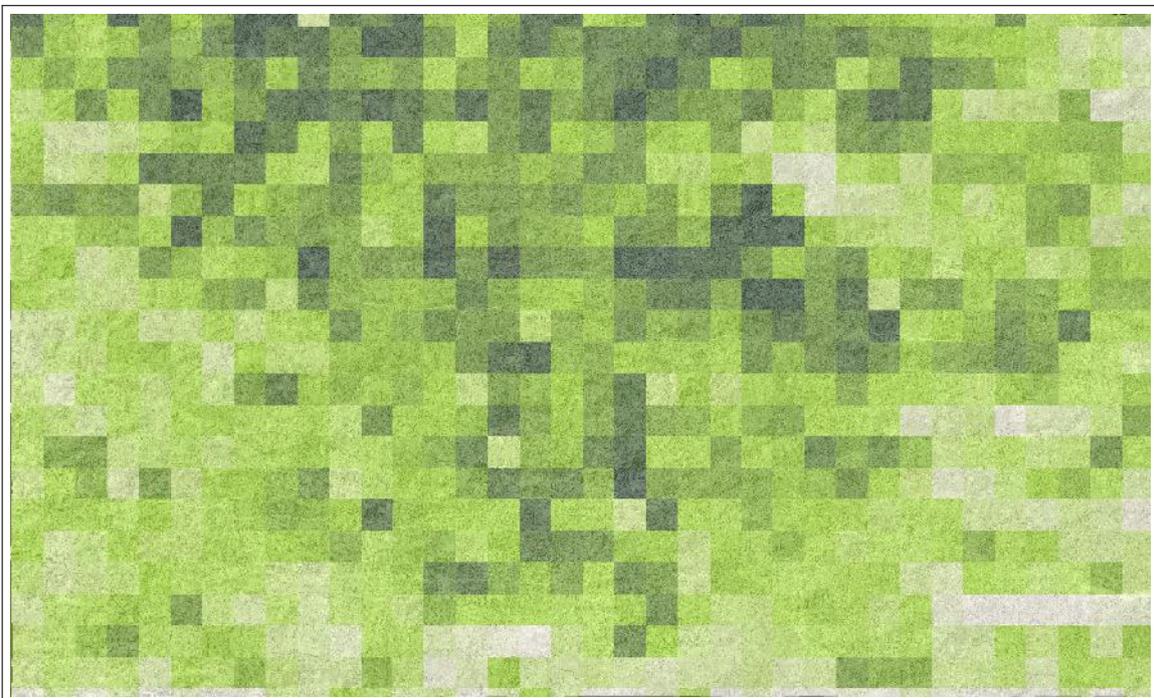
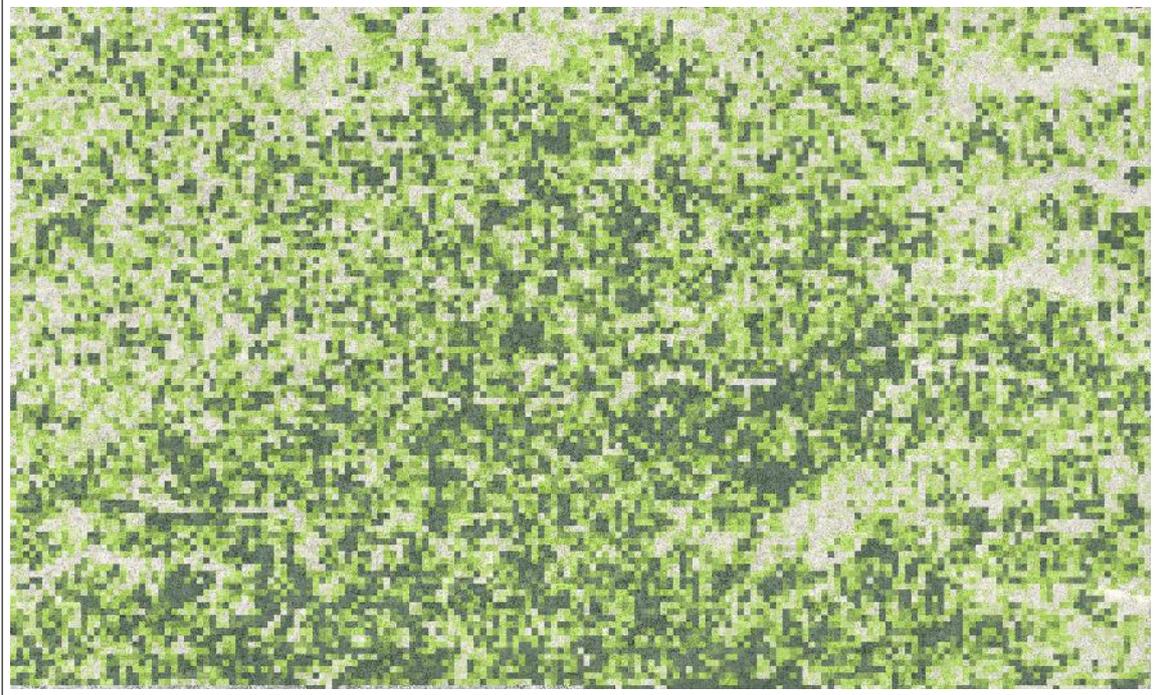
Détail des 2 méthodes utilisées





Autres sous-produits

Proportion de sursol (aire en sursol/aire totale) pour deux tailles de fenêtres différentes sur la zone entière (20km de longueur).

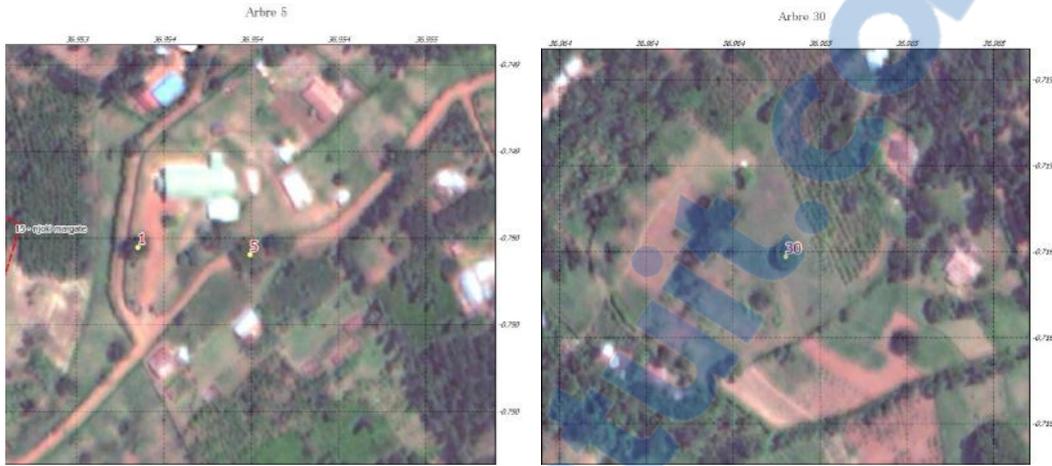


Légende :
Blanc=0% de sursol
Vert le plus foncé= 18%

M

Tableau récapitulatif des arbres mesurés sur le terrain

Extrait des planchettes utilisées pour les mesures sur le terrain



Rapport-Gratuit.com

Tableau des arbres mesurés sur le terrain

id	nom_martha	Altitude	GPS_X	GPS_Y	HEIGHT	SPECIES
1	27	1782	272303	9921272	9.5	AVOCADO
2	29	1795	272483	9921222	15.5	MUKINDURI
3	30	1654	273897	9919279	13.4	MANGO
4	9T1	1581	283012	9919063	19.3	GREVILLEA
5	34	1600	282935	9919480	29.4	PODO
6	35	1609	282708	9919373	13.4	MANGO
7	33	1628	282081	9920144	12	MANGO
8	36	1617	282771	9919313	14.8	MACADAMIA
9	IT1	1608	282608	9919588	10	MANGO
10	10	1707	276327	9918815	12.5	MANGO
11	11	1678	276020	9919069	9.2	MANGO
12	12	1727	275981	9918838	18.4	PINE
13	13	1728	275821	9918709	13.8	PINE
14	14	1698	276078	9918771	13.4	AVOCADO
15	16	1730	275829	9918570	11	MAUCINGIRI
16	17	1701	275701	9918501	15.7	MUHUTI
17	18	1711	275693	9918486	15.8	MUHUTI
18	19	1720	275272	9918370	11.5	AVOCADO
19	5T1	Inconnue	278588	9916900	22.6	GREVILLEA
20	6	1751	275046	9917668	12.5	MANGO
21	7	1702	276454	9917086	12.6	MANGO
22	8	1650	278132	9917166	30.9	EUCALYPTUS
23	TREE NUMBER ONE	1715	275986	9918868	19.4	GREVILLEA
24	TREE NUMBER THREE	1713	275825	9918770	12.7	MANGO
25	TREE NUMBER FOUR	1690	276064	9918865	27	EUCALYPTUS
26	TREE NUMBER FIVE	1715	276078	9918818	7.7	AVOCADO
27	TREE NUMBER 37	1634	282146	9920235	18	AVOCADO
28	ANOTHER ISOLATED TREE	1640	282093	9920320	20	MUKUHU
29	ANOTHER ISOLATED TREE	1622	281995	9920428	15	MANGO

N

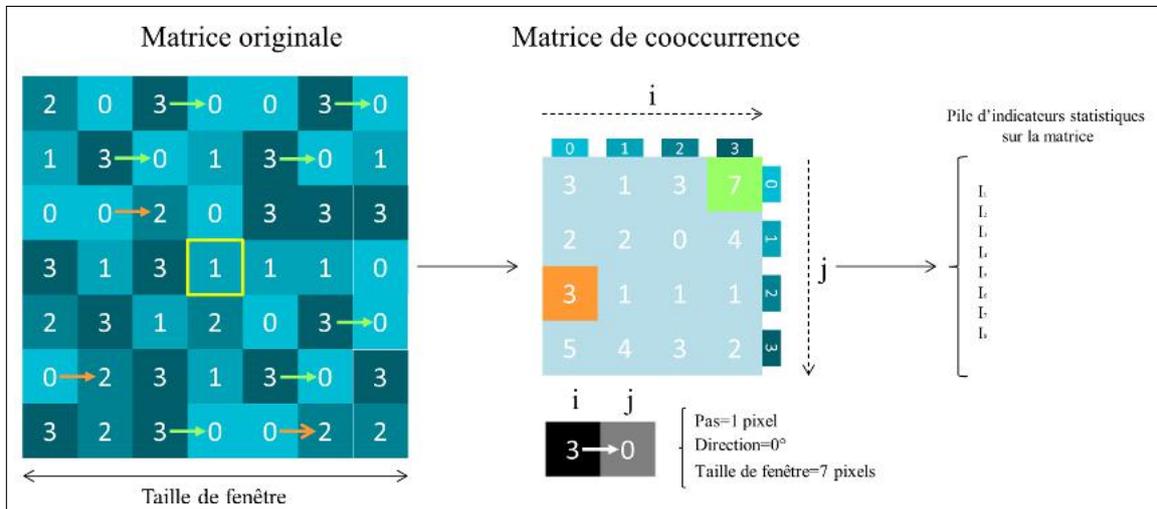
Jeu d'apprentissage

Nom de la classe	Abrégé	Nombre d'échantillons
Cultures vivrières/maraichage et napier	VI	111
Théiers	THE	54
Caféiers au soleil	CA1	49
Caféiers sous ombre	CA2	62
Bananiers	BAN	44
Couvert arboré	ARB	116
Plantation d'Eucalyptus	EUC	30
TOTAL		466

O

Création des indices d'Haralick

Les indices d'Haralick sont créés en calculant la matrice de co-occurrence pour chaque pixel de l'image. La taille de fenêtre définit le voisinage dans lequel on compte les transitions entre une valeur et une autre. Dans l'exemple ci-dessous, une direction horizontale vers la droite est utilisée.

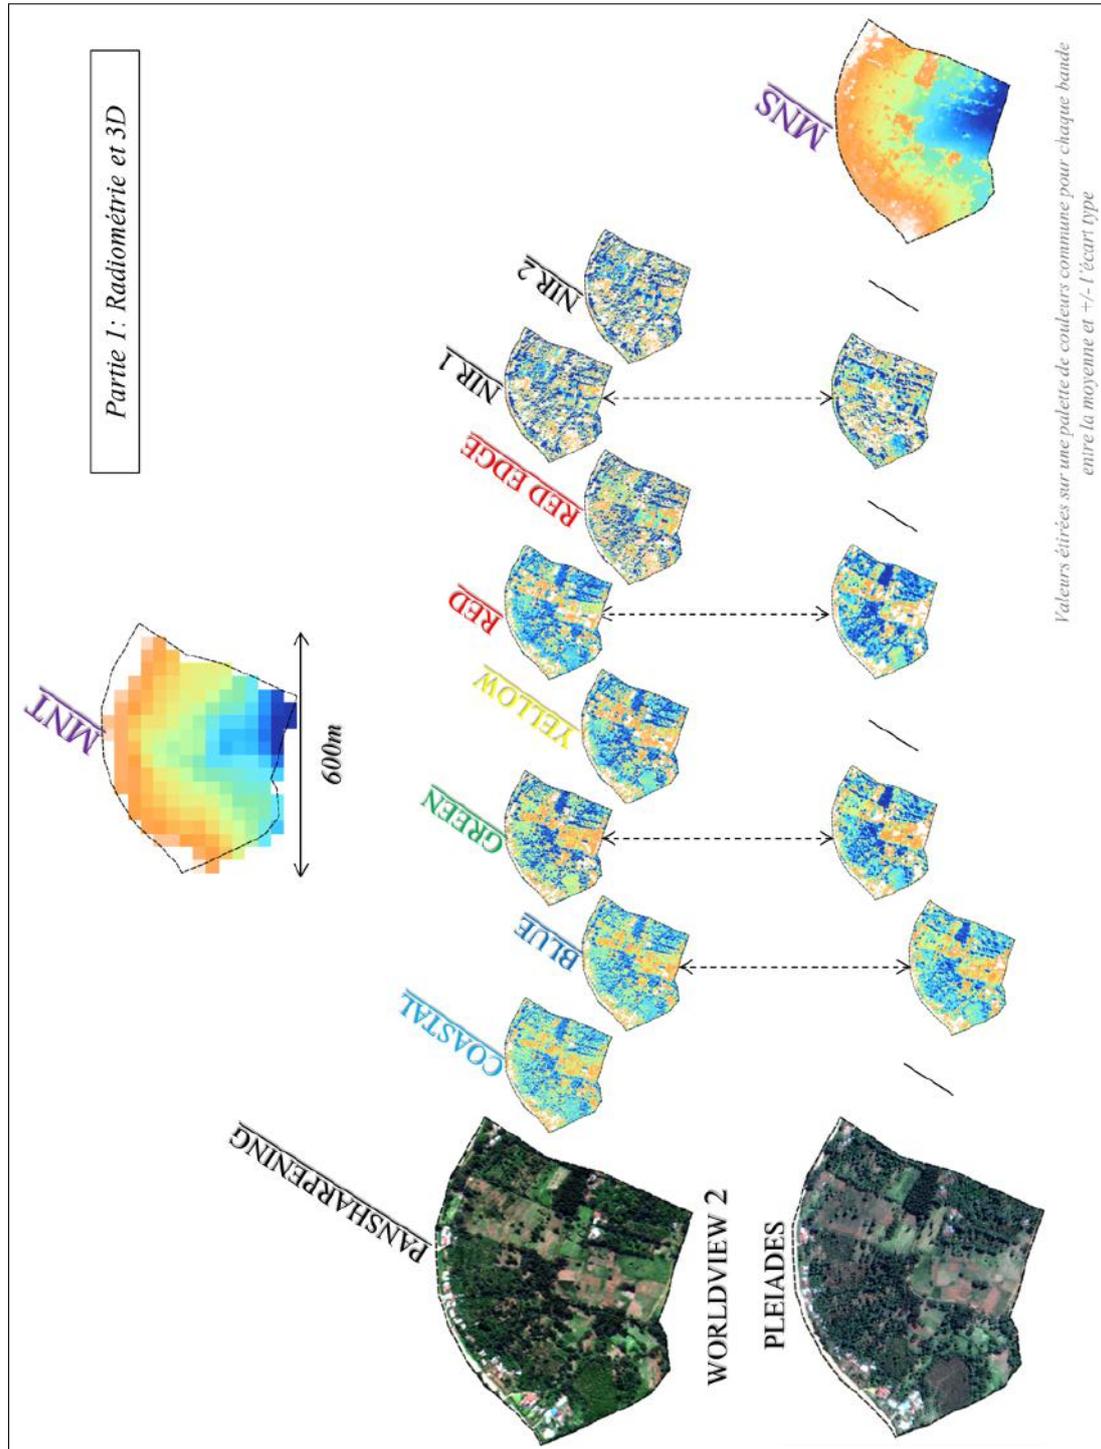


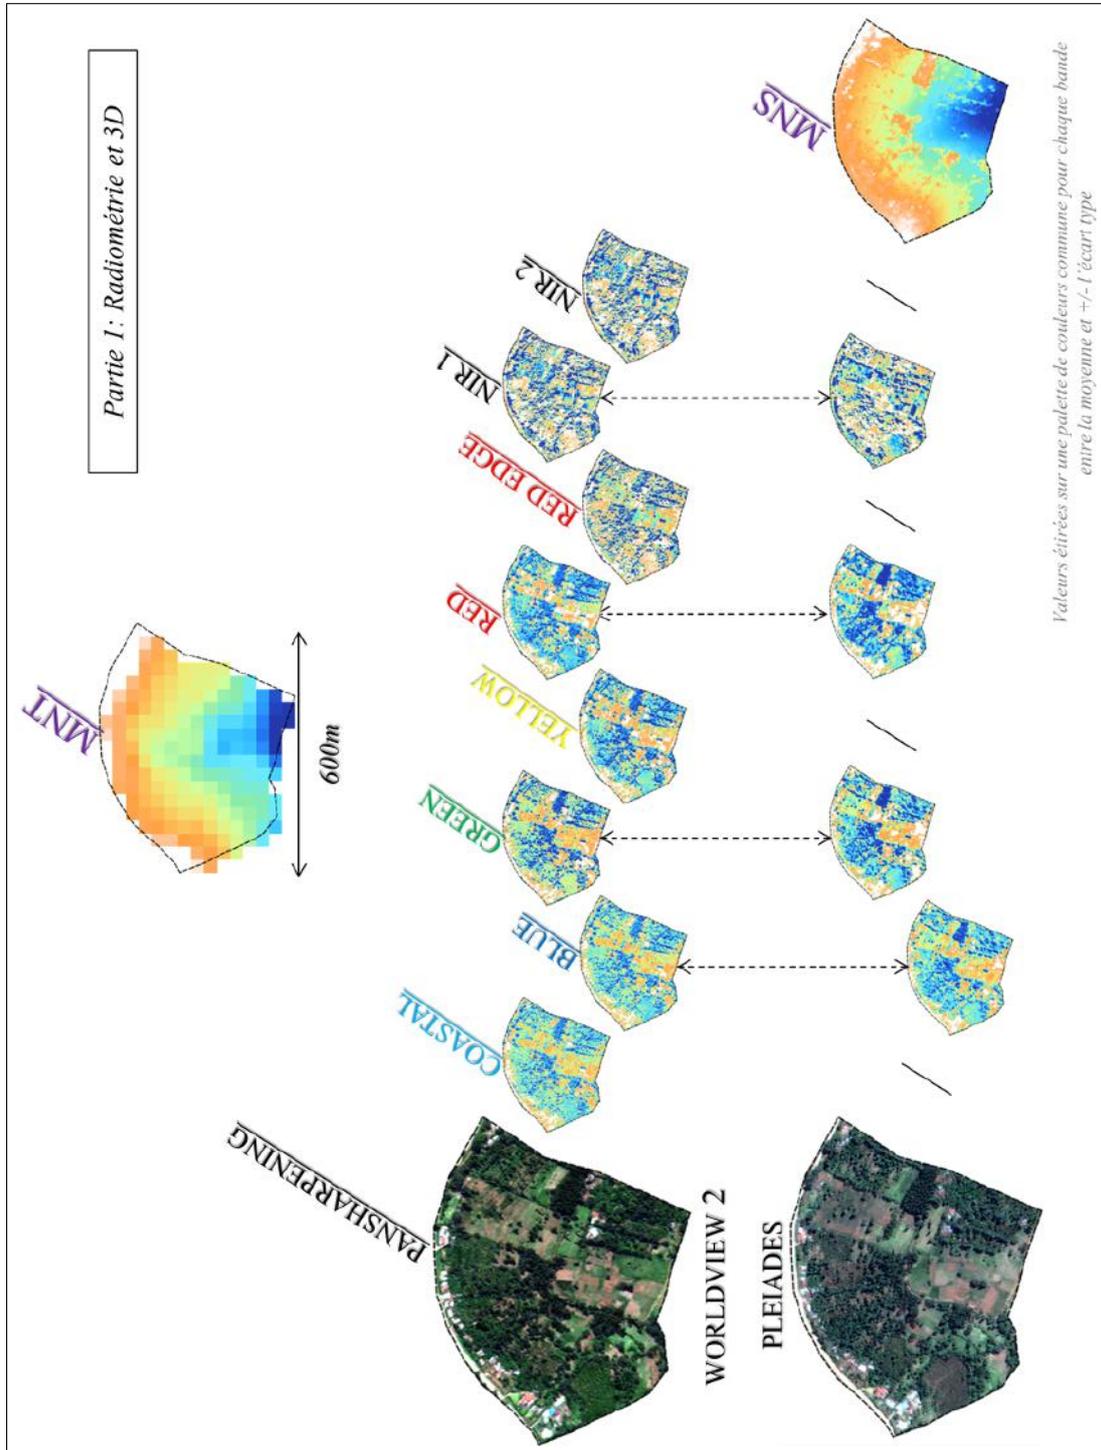
Il est alors possible de réaliser des statistiques sur cette matrice de cooccurrence. Les noms sont laissés non traduits afin de correspondre sans ambiguïté à leur dénomination au sein du logiciel.

Nom	Formule
Mean	$f_1 = \frac{\sum_i \sum_j p(i,j)}{z^2}$
Variance	$f_2 = \sum_i \sum_j p(i,j)(i - U)^2$
Homogeneity	$f_3 = \sum_i \sum_j \frac{1}{1+(i-j)^2}$
Contrast	$f_4 = \sum_{n=0}^{Ng-1} n^2 [\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j)]$
Dissimilarity	$f_5 = \sum_{n=0}^{Ng-1} n^2 [\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j)^2]$
Entropy	$f_6 = \sum_i \sum_j p(i,j) \log(p(i,j))$
Second Moment	$f_7 = - \sum_i \sum_j [p(i,j)]^2$
Correlation	$f_8 = \frac{\sum_i \sum_j (ij)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$

P

Présentation des attributs utilisés pour la classification





Q

Script R utilisé pour la classification

Ce script résumé comprend les grandes lignes du script original, il ne présente pas en détail les différents tests effectués

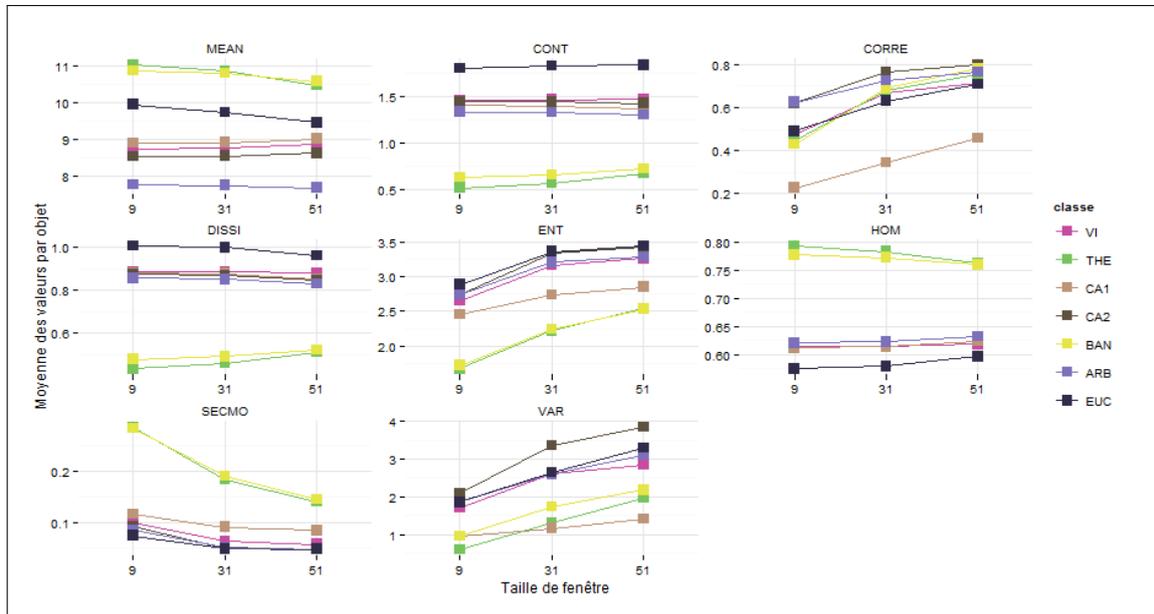
```
1 #Liste des packages
2 #####
3 library(randomForest)
4 library(foreign)
5 library(ggplot2)
6 library(reshape)
7 library(scales)
8 library(e1071)
9 library(rgdal)
10 library(maptools)
11 library(dplyr)
12 library(mapproj)
13 library(SDMTools)
14 library(caret)
15 #####
16
17
18 #Ouverture du fichier csv contenant les donnees d'apprentissage.
19 #Celui-ci possede une colonne dediee a la classe et le reste des colonnes
   contenant les difereents attributs
20 learning_sample=read.table("D:\\Florian\\Segmentation\\apprentissage2_classe.csv",
   header=TRUE, sep=";")
21 #Suppression des classes non vegetales
22 learning_sample=learning_sample[which(learning_sample$CLASSE2 %in% c("VI", "THE",
   "CA1", "CA2", "BAN", "ARB", "EUC")),]
23 #Reorganisation des niveaux de classe
24 learning_sample$CLASSE2 = factor(learning_sample$CLASSE2, levels=c("VI", "THE", "
   CA1", "CA2", "BAN", "ARB", "EUC"))
25
26 #Separation du jeu d'apprentissage en deux partie de maniere aleatoire
27 #Indice des lignes dans la matrice
28 lignes=1:nrow(learning_sample)
29 #Choisir la moitie des lignes au hasard la dedans => fonction sample
30 partie1=sample(lignes, nrow(learning_sample)/2)
31 partie2=lignes[-partie1]
32 #Classes reference
33 ref=learning_sample[partie2,]$CLASSE2
34
35 #####MODELE RANDOM FOREST#####
36 modele=randomForest(CLASSE2~., data=learning_sample[partie1,], norm.votes=TRUE,
   importance=TRUE, proximity=TRUE)
37 pred=predict(modele, learning_sample[partie2,])
38 matrice_confusion=confusionMatrix(pred, ref)
39 p_succes=matrice_confusion$overall[[2]]
40
41 #####MODELE SVM#####
42 #4 noyaux utilises: linear, radial, polynomial, sigmoid
43 #Ajuster les parametres du svm au jeu de donnees que l'on possede
44 param_ajuste=tune(svm, CLASSE2~., data=learning_sample)
45 cout=param_ajuste$best.model$cost
46 gamma_=param_ajuste$best.model$gamma
47 tout=2:ncol(learning_sample)
48 modele= svm(CLASSE2 ~ ., data = learning_sample[partie1,], cost = cout, gamma=
   gamma_, kernel="linear")
```

```

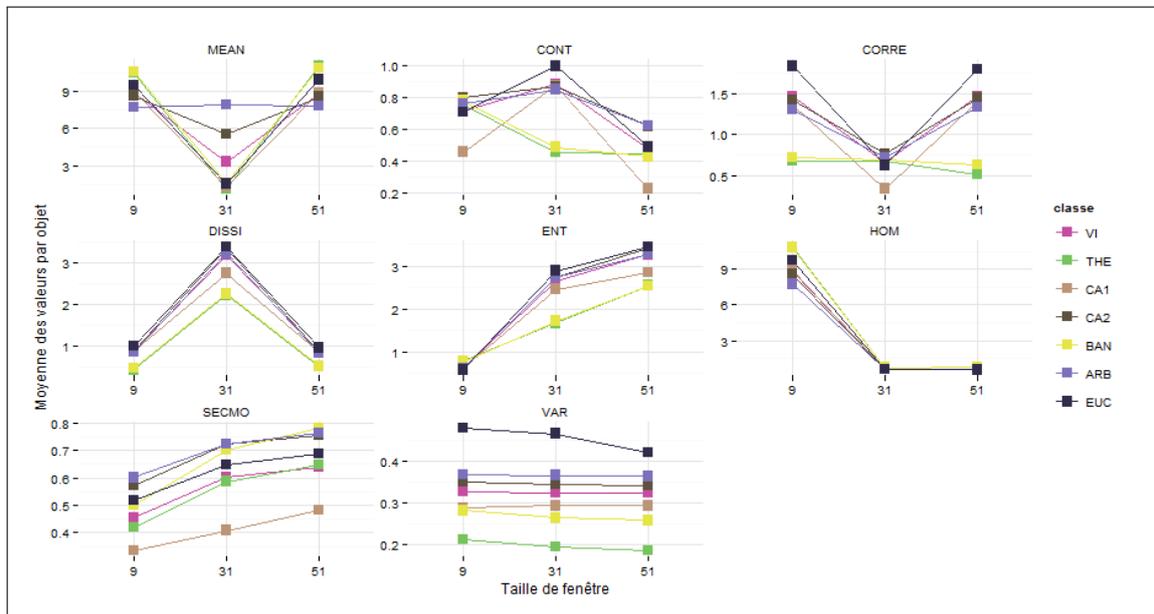
49 pred=predict(modele, learning_sample[partie2,])
50 matrice_confusion=confusionMatrix(pred, ref)
51 p_succes=matrice_confusion$overall[[2]]
52
53
54 #####
55 #Ouverture des donnees des 5 zones a predire sous forme de tableau
56 setwd("D:\\Florian\\Segmentation\\Zones_test_segmentation")
57 #Liste des shapefiles du dossier
58 files <- list.files(pattern="*.shp", recursive=TRUE, full.names=TRUE)
59 uid=1
60
61 #Initialisation de la fusion des shapefiles
62 liste_extent={}
63 poly.data<- readOGR(files[1], gsub("^.*(.*).shp$", "\\1", files[1]))
64 n <- length(slot(poly.data, "polygons"))
65 poly.data <- spChFIDs(poly.data, as.character(uid:(uid+n-1)))
66 uid <- uid + n
67 liste_extent[[1]]= extent(poly.data)[1:4]
68 poly.data$zone=1
69
70 #Fusion des autres shapefiles
71 for (i in 2:length(files)) {
72   temp.data <- readOGR(files[i], gsub("^.*(.*).shp$", "\\1", files[i]))
73   temp.data$zone=i
74   liste_extent[[i]]= extent(temp.data)[1:4]
75   n <- length(slot(temp.data, "polygons"))
76   temp.data <- spChFIDs(temp.data, as.character(uid:(uid+n-1)))
77   uid <- uid + n
78   poly.data <- spRbind(poly.data, temp.data)
79 }
80
81
82 #Prediction par un des modeles
83 a_predire=poly.data@data
84 prediction=predict(modele, a_predire)
85 a_predire$PRED=prediction
86 a_predire$id=1:nrow(a_predire)
87 poly.data@data=a_predire
88 #Ecriture du shapefile avec une colonne prediction
89 writeOGR(poly.data, ".", "zone_ensemble_predit", driver="ESRI Shapefile")
90 #Transformation des donnees pour representation directe avec ggplot
91 tract <- fortify(poly.data, region="id")
92 tract$id=as.numeric(tract$id)
93 jointure=poly.data@data[, c("id", "PRED", "zone")]
94 plotData <- left_join(tract, jointure)
95 #Creation de la figure
96 ggplot()+
97   geom_polygon(data = plotData, aes(x = long, y = lat, group=group, fill=PRED),
98     color = NA, size = 0, alpha = 7/10)+
99   theme_minimal()+
100   coord_equal()+
101   scale_fill_manual(values=couleurs2)+
102   facet_wrap(~zone, scales="free", ncol=5)

```

PLEIADES



WORLDVIEW 2

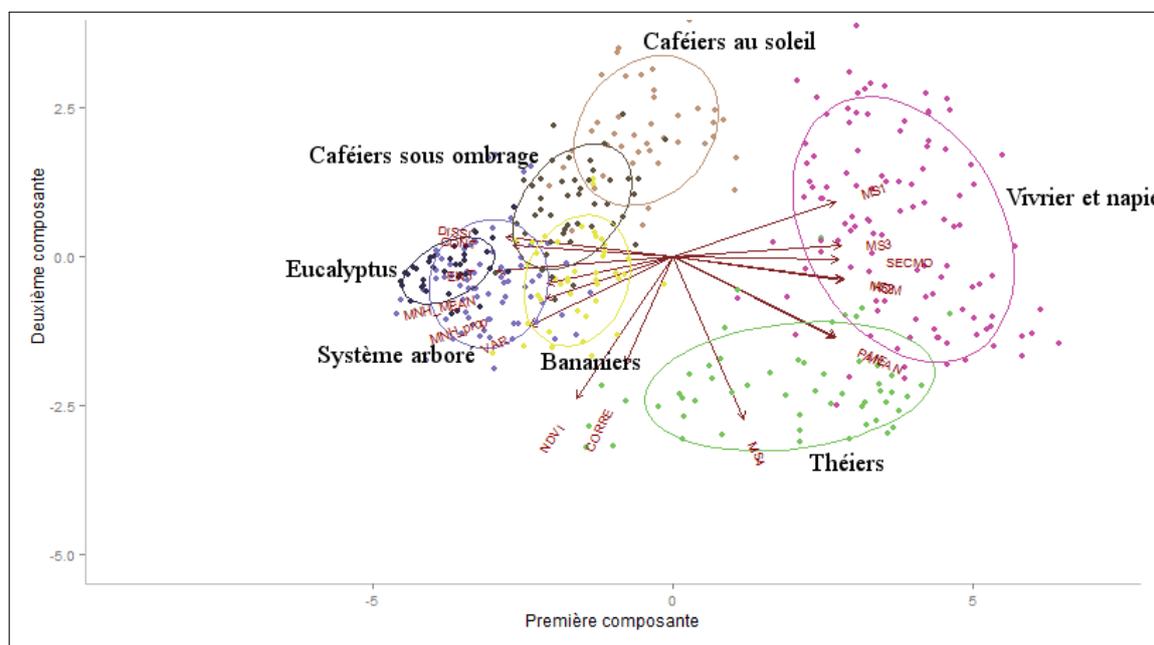


S

Analyse ACP des données d'apprentissage

Nous allons ici procéder à une analyse préliminaire du jeu d'apprentissage. On décide de réaliser d'abord une Analyse en composantes principales (ACP) sur les données, choix motivé par le caractère quantitatif de tous les attributs et la volonté de voir comment il est possible de regrouper certains d'entre eux selon leur contribution à la détermination de la classe. On créera pour l'occasion une deuxième classe CLASSE_HAUTEUR qui est une simplification de la classe CLASSE_VEGETATION tenant simplement compte du type de structure verticale avec 3 possibilités allant de l'absence de couvert au couvert total.

L'analyse et les figures sont réalisées à l'aide du langage statistique R. Nous pouvons ainsi représenter la contribution aux deux premiers axes de l'ACP des différentes variables. Par soucis de visibilité, les indices d'Haralick de taille différente ont été regroupés en une seule variable égale à la moyenne des 4 tailles de fenêtre. Le choix est discutable mais est réalisé ici par soucis de simplicité des figures.



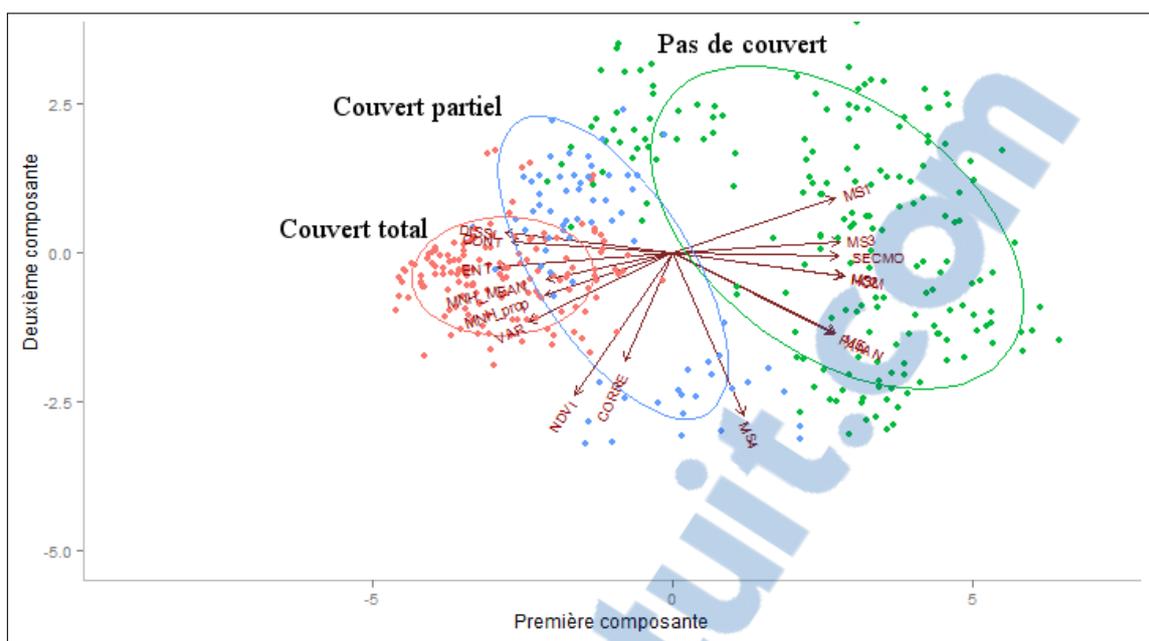
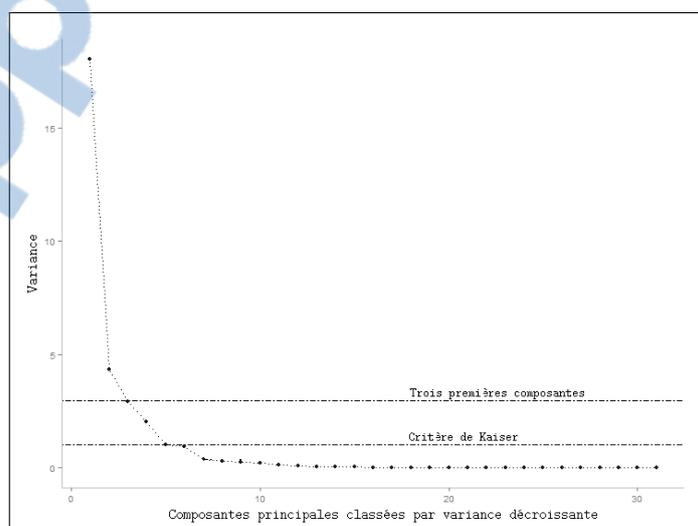


FIGURE S.1 – Représentation des classes de données sur les 2 premières composantes de l'ACP

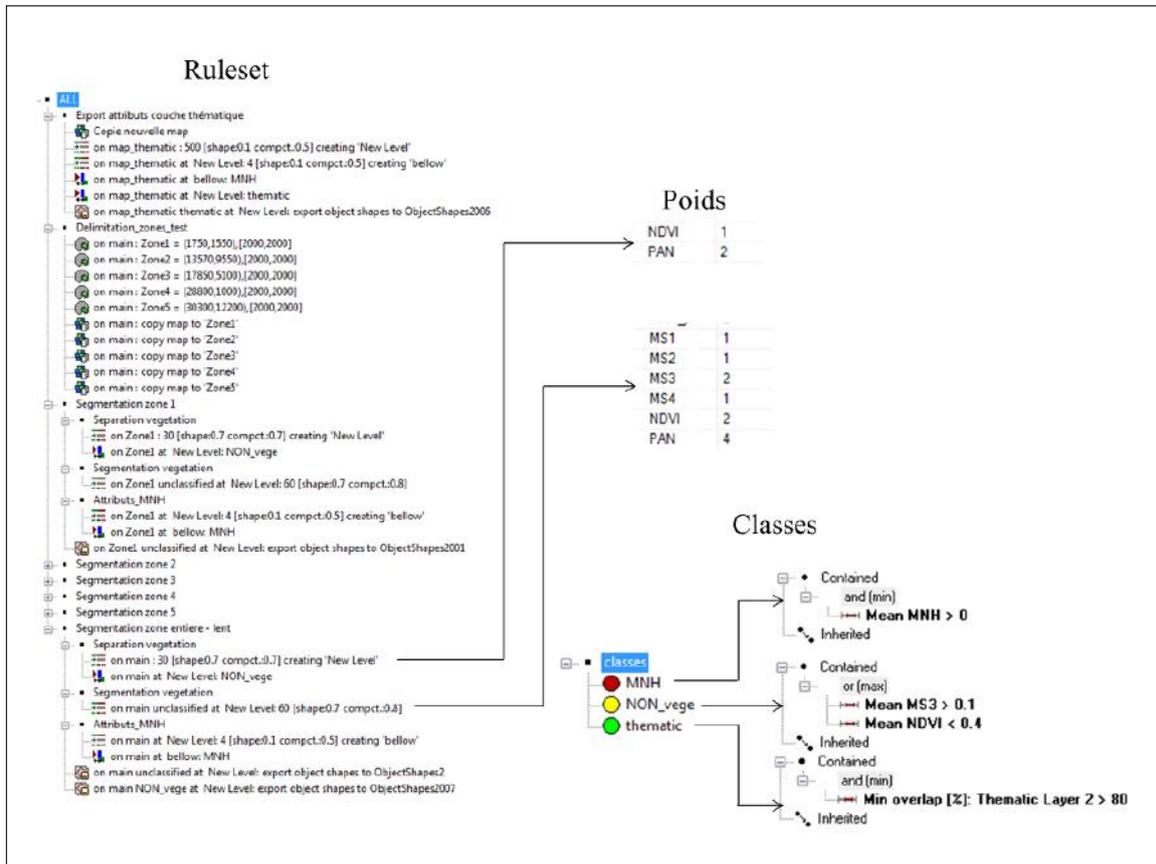
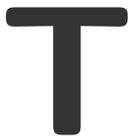
Les groupes de végétation sont plutôt bien individualisés même s'il y a des chevauchements. Ici c'est la première composante qui prédit particulièrement bien CLASSE_HAUTEUR en adressant son gradient de hauteur. En outre, trois groupes de variables se distinguent ici : celles prédisant les cultures arborées sont principalement des indices de texture et sans surprise les indices issus du MNH, alors que la radiométrie joue un rôle plus important pour la prédiction des cultures basses. Les données issues de l'infrarouge et l'indice de corrélation semblent quant à eux définir une 3ème classe le long de la seconde composante dont l'utilité est plus complexe à définir. Les différentes composantes de l'ACP pourraient être utilisées comme variables pour la classification mais nous avons décidé de ne pas explorer cette piste car elles sont plus difficiles à interpréter sans garantie d'apporter une information nouvelle par rapport aux variables existantes, auxquelles elles sont totalement corrélées. .

Variance expliquée par les premières composantes de l'ACP



	Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6	Comp.7	Comp.8
MS1	-0,01	-0,3	-0,07	0,02	-0,23	0,31	0,07	0,21
MS2	-0,03	-0,33	-0,01	-0,07	-0,11	0,15	-0,03	0,01
MS3	-0,07	-0,28	-0,09	0,06	-0,11	0,15	0,08	-0,1
MS4	0	-0,04	0,33	-0,38	0,28	-0,18	0,01	-0,12
NDVI	-0,03	0,17	0,27	-0,24	0,35	-0,23	-0,03	-0,18
PAN	-0,01	-0,29	0,16	-0,26	-0,02	0,13	0,04	0,08
CONT_31	-0,2	-0,2	0,02	0,2	0,18	-0,1	0,01	-0,03
CONT_51	-0,21	-0,12	0,02	0,16	0,07	-0,25	0,39	0,07
CONT_9	-0,17	-0,21	0,02	0,2	0,22	-0,01	-0,23	-0,08
CORRE_31	-0,05	-0,07	-0,42	-0,25	0	-0,18	-0,17	-0,04
CORRE_51	-0,01	-0,08	-0,39	-0,27	0,08	-0,22	-0,09	-0,04
CORRE_9	-0,11	-0,04	-0,37	-0,22	-0,05	-0,02	-0,22	-0,06
DISSI_31	-0,27	-0,03	0,1	0,07	-0,02	0,05	0	-0,01
DISSI_51	-0,26	0,05	0,08	0,04	-0,1	-0,1	0,29	0,08
DISSI_9	-0,26	-0,06	0,11	0,09	0,04	0,13	-0,22	-0,06
ENT_31	-0,27	0,04	-0,07	-0,1	-0,14	0,01	-0,07	-0,03
ENT_51	-0,24	0,05	-0,13	-0,13	-0,15	-0,15	0,22	0,06
ENT_9	-0,25	0,1	0,1	-0,09	-0,07	0,11	-0,21	-0,03
HOM_31	0,26	-0,09	-0,13	0	0,1	-0,07	0,01	-0,01
HOM_51	0,24	-0,11	-0,1	0,01	0,13	0,06	-0,21	-0,09
HOM_9	0,25	-0,09	-0,17	0,01	0,06	-0,14	0,16	0,02
MEAN_31	0,04	-0,29	0,17	-0,28	-0,02	-0,01	0,09	0,07
MEAN_51	0,09	-0,25	0,15	-0,23	-0,07	-0,12	0,04	0,02
MEAN_9	-0,01	-0,29	0,16	-0,27	-0,01	0,12	0,05	0,08
SECMO_31	0,24	-0,1	0,02	0,14	0,17	0,05	0,13	0,01
SECMO_51	0,23	-0,09	0,08	0,13	0,17	0,19	-0,11	-0,06
SECMO_9	0,23	-0,11	-0,14	0,13	0,09	-0,08	0,24	-0,01
VAR_31	-0,16	-0,24	-0,05	0,16	0,22	-0,08	-0,08	0
VAR_51	-0,17	-0,2	-0,13	0,12	0,18	-0,26	0,19	0,08
VAR_9	-0,16	-0,22	-0,02	0,18	0,23	-0,03	-0,27	-0,07
Prop_MNH	-0,12	0,04	-0,18	-0,12	0,17	0,43	0,41	-0,68
SD_MNH	-0,09	0,15	-0,12	-0,14	0,39	0,24	0,06	0,54
Mean_MNH	-0,1	0,14	-0,15	-0,11	0,39	0,34	0,1	0,27

Tableau des loadings pour chaque composante

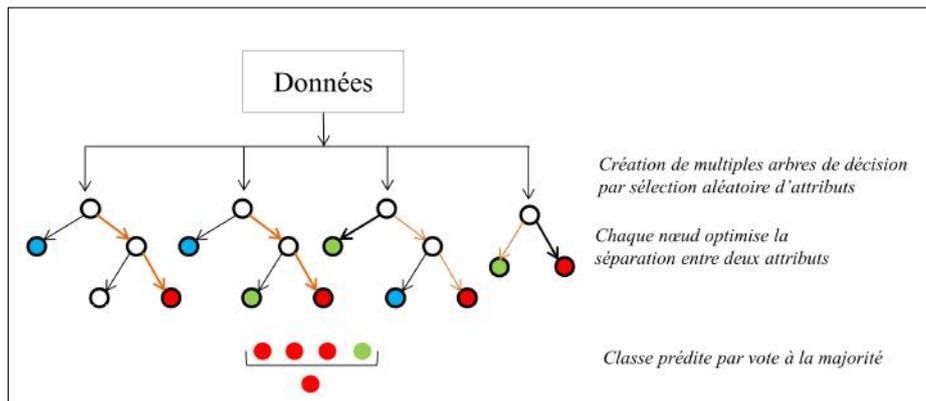


Soit la matrice de données suivantes :

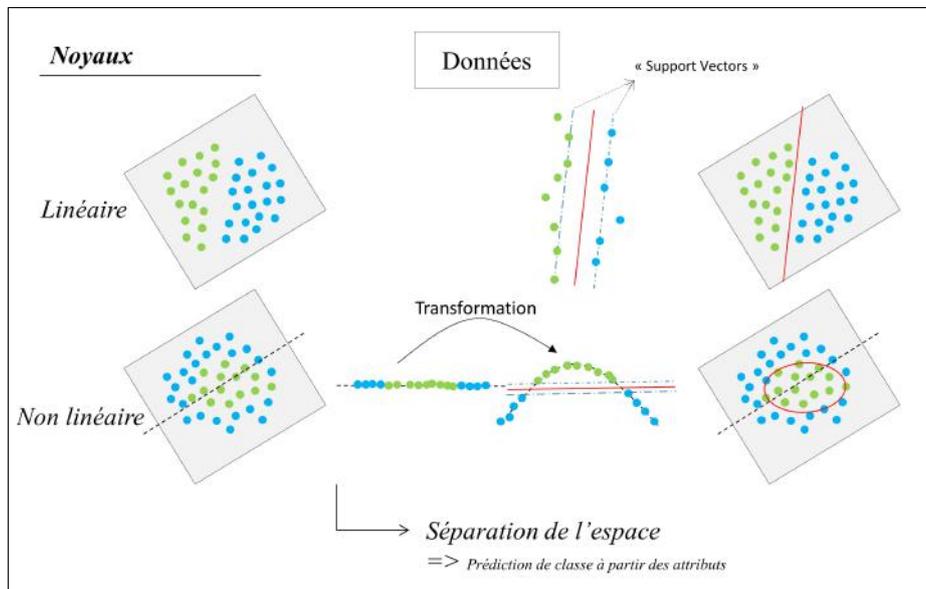
$$\begin{matrix}
 & \underbrace{\hspace{10em}}_{n \text{ attributs et } 1 \text{ classe}} \\
 \left. \begin{matrix} p \text{ échantillons} \\ \vdots \\ \vdots \\ \vdots \end{matrix} \right\} & \begin{pmatrix} V_{1,1} & V_{1,2} & V_{1,3} & \cdot & \cdot & \cdot & V_{1,n} & C_1 \\ V_{2,1} & V_{2,2} & V_{2,3} & \cdot & \cdot & \cdot & V_{2,n} & C_2 \\ \cdot & \cdot \\ \cdot & \cdot \\ V_{p,1} & V_{p,2} & V_{p,3} & \cdot & \cdot & \cdot & V_{p,n} & C_p \end{pmatrix}
 \end{matrix}$$

L'objectif des deux algorithmes est d'utiliser les colonnes d'attributs pour apprendre la règle de décision qui prédira au mieux la colonne classe. Il sera ainsi possible de prédire la classe d'un ensemble d'attributs connus avec les règles de l'apprentissage.

Random forest

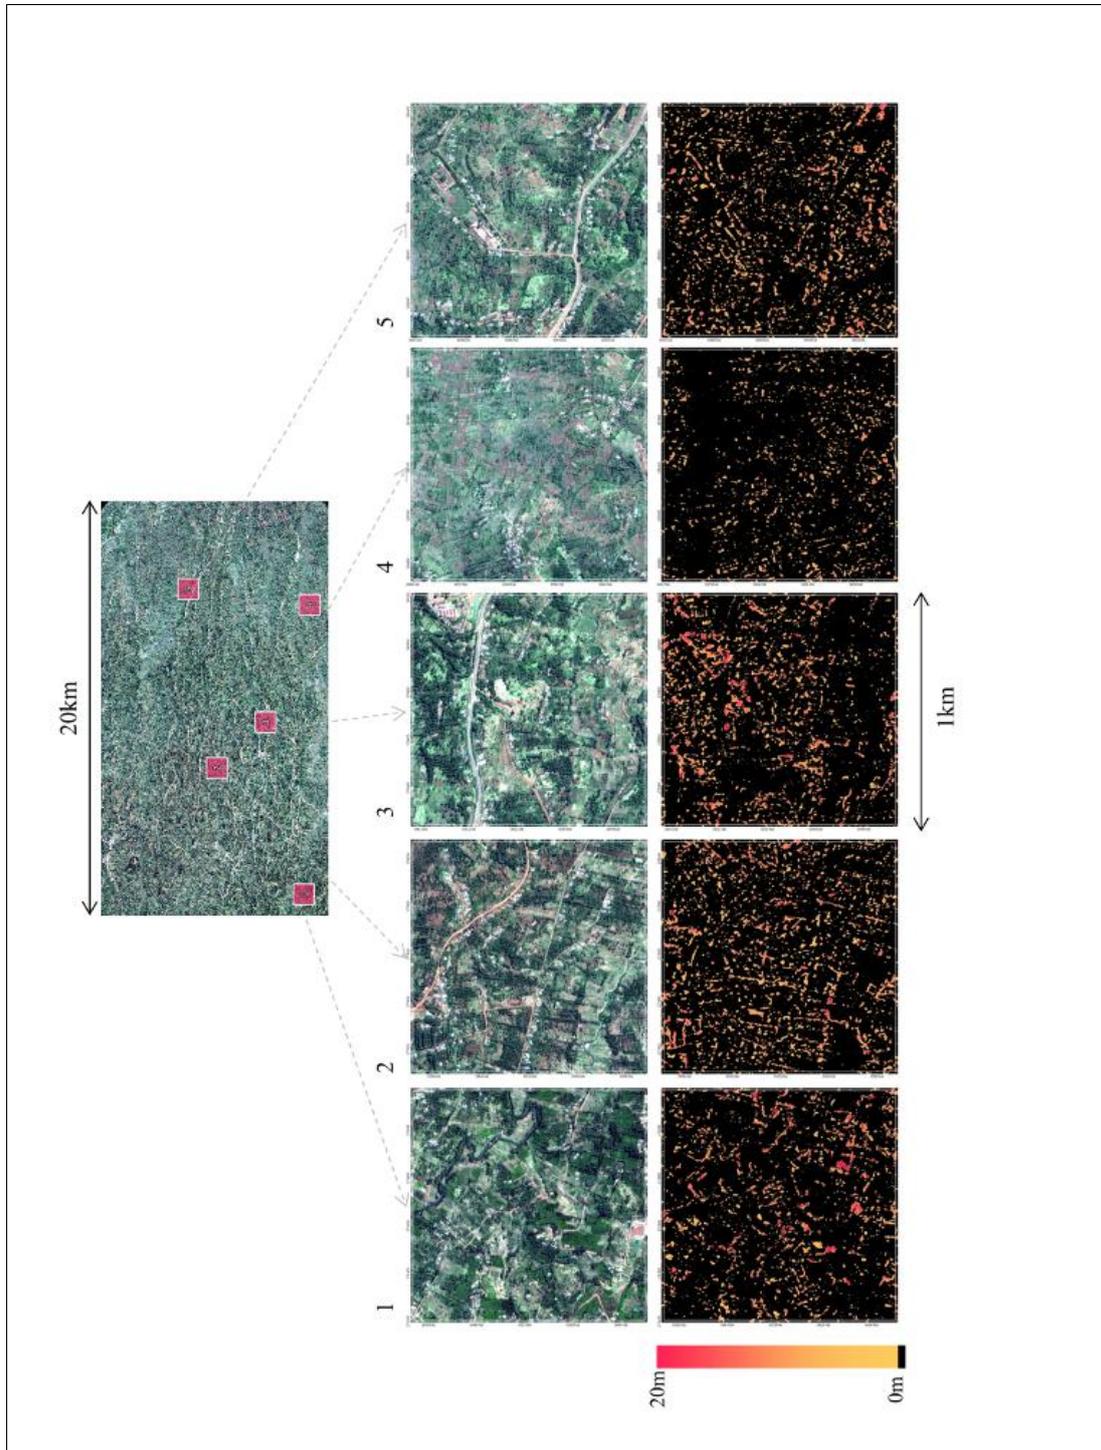


SVM



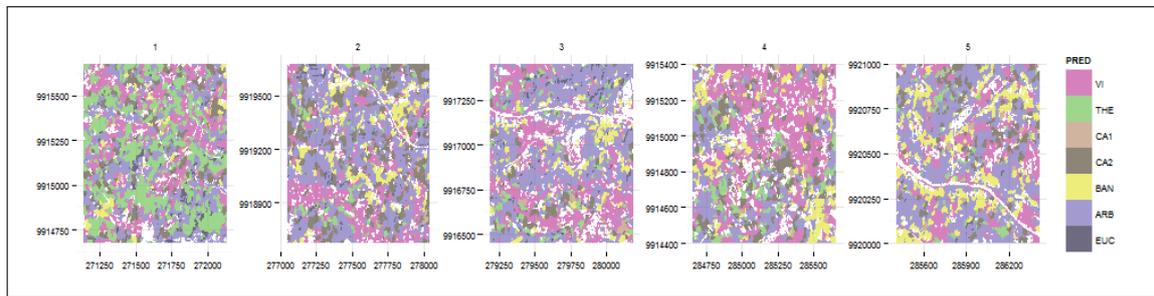


Planches de classification sur les 5 zones

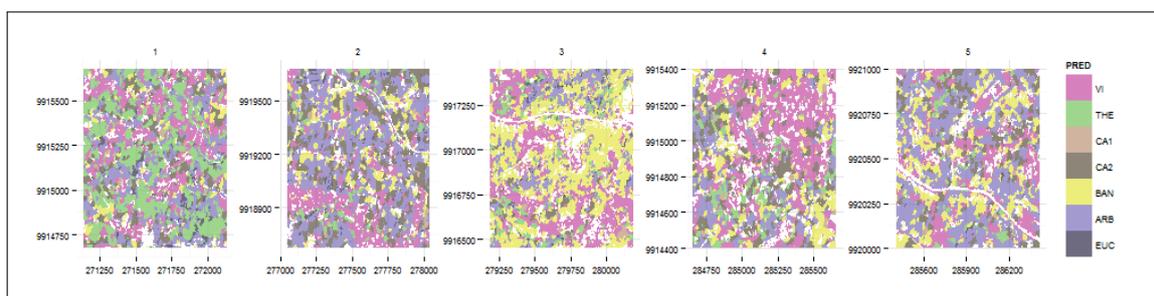


Test des différentes stratégies sur le Random Forest

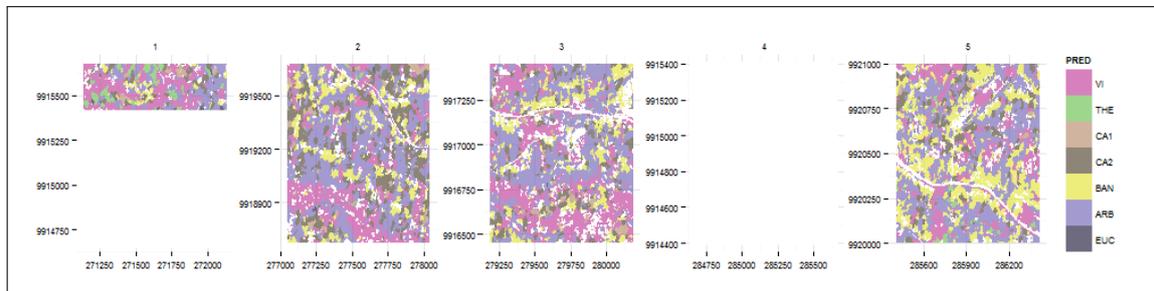
PLEIADES SEUL



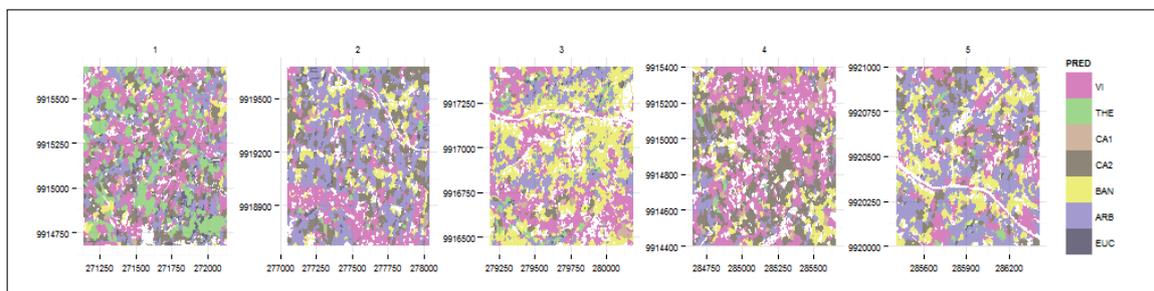
PLEIADES + 3D



WORLDVIEW SEUL

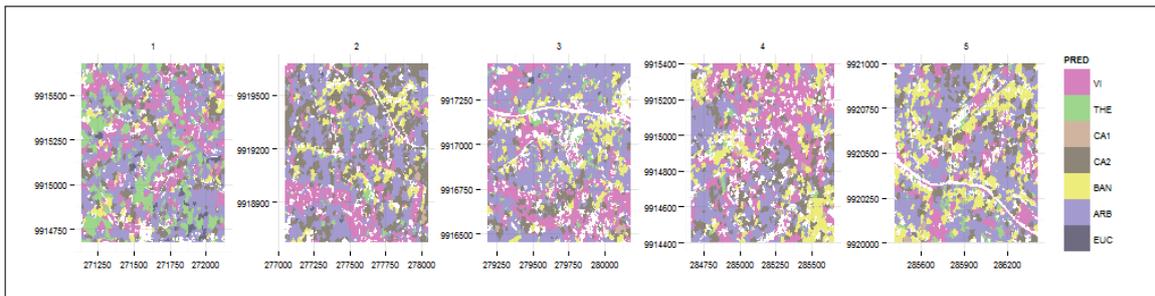


WORLDVIEW + PLEIADES 3D

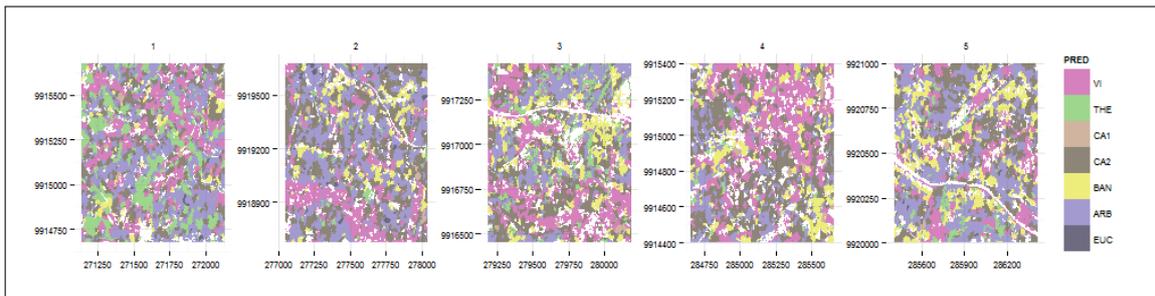


Test des différentes stratégies sur le SVM linéaire

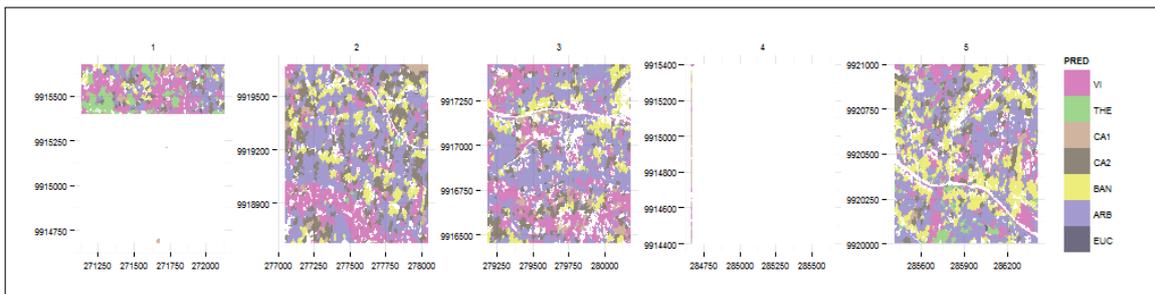
PLEIADES SEUL



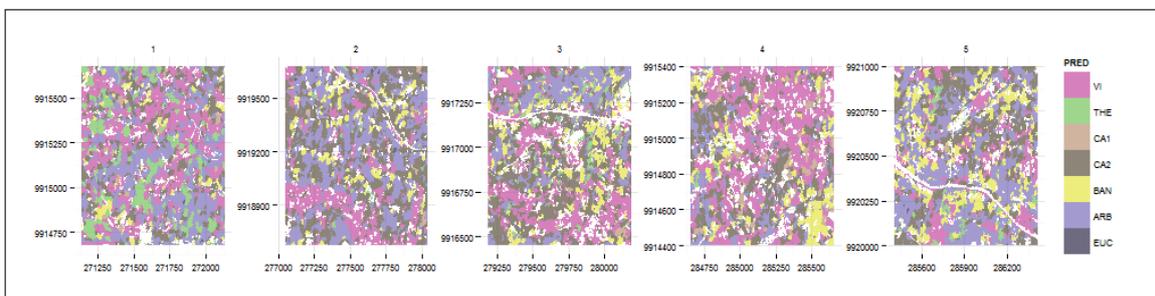
PLEIADES + 3D



WORLDVIEW SEUL

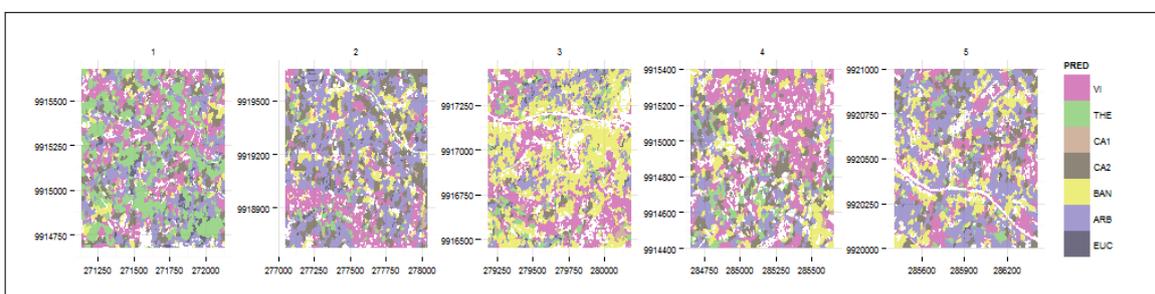


WORLDVIEW + PLEIADES 3D

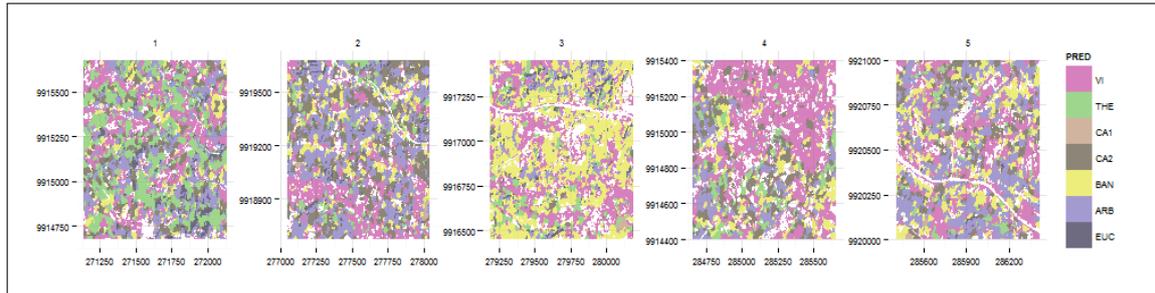


Test des différents algorithmes sur les données Pléiades + 3D

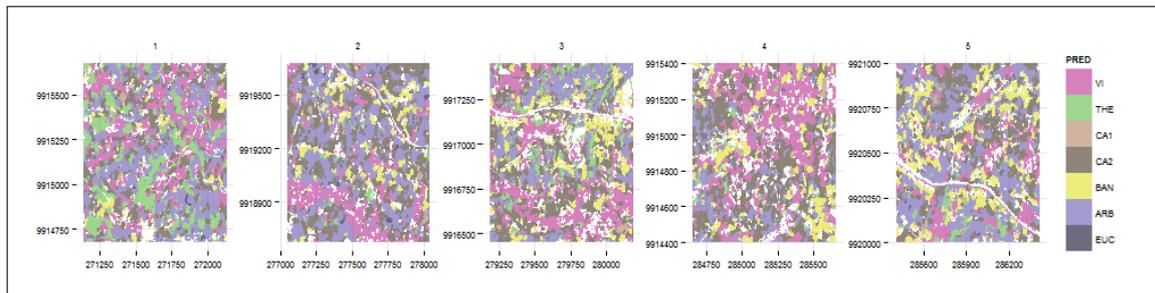
Random Forest base (nvariable à chaque arbre= $\sqrt{\text{nombre d'attributs}}$)



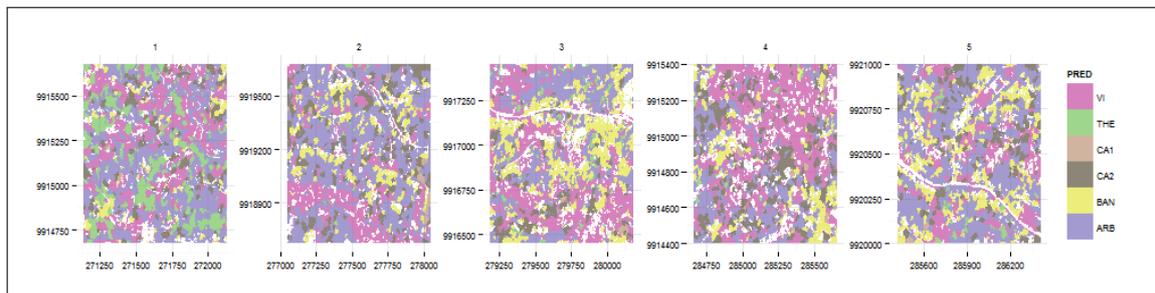
Random Forest modifié (nvariable à chaque arbre= nombre d'attributs)



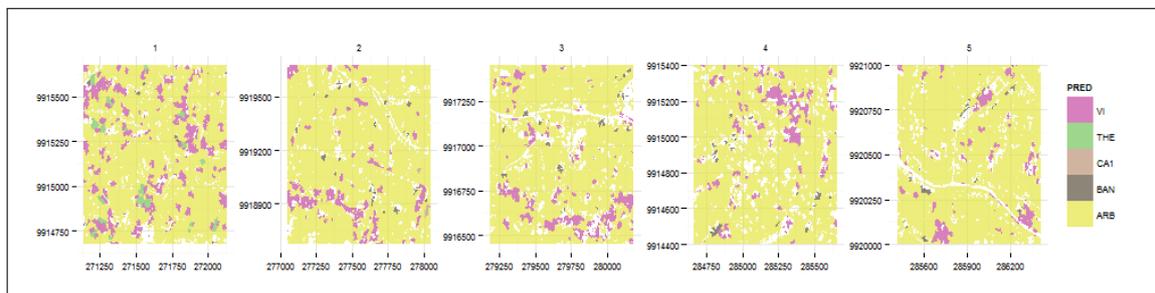
SVM à noyau linéaire



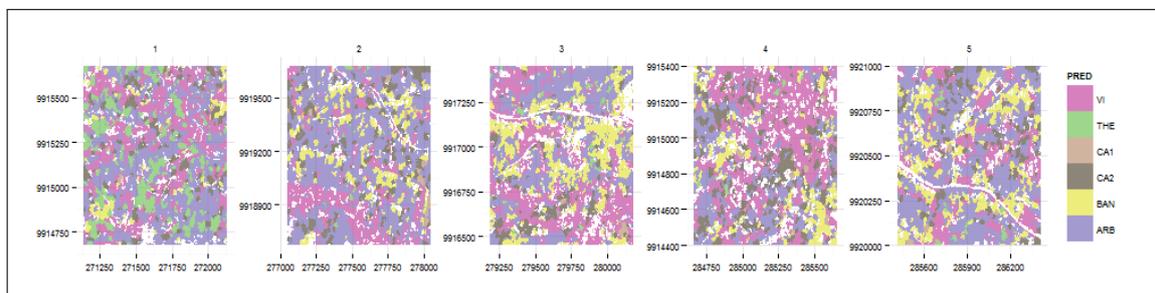
SVM à noyau radial



SVM à noyau polynomial

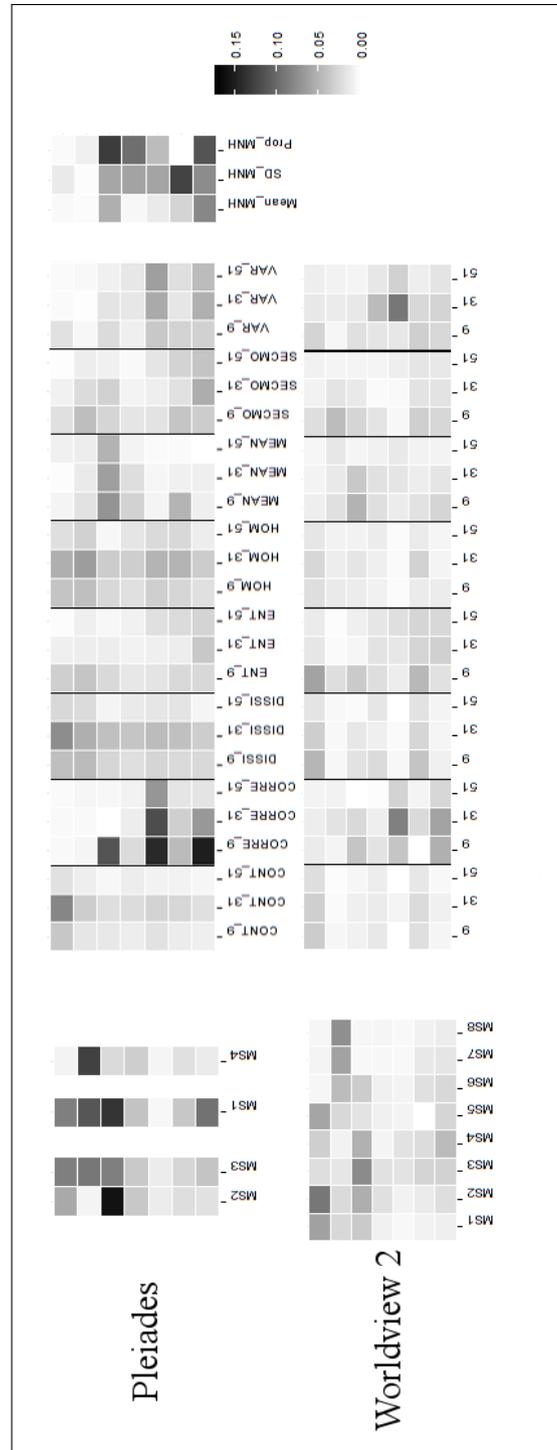


SVM à noyau sigmoïde





Importance des variables du Random Forest pour chaque classe



Y

Incertitudes sur les résultats

Description/Problèmes rencontrés	Importance	Quantifiable?
Prétraitement des images Pléiades		
Précision altimétrique du MNH <i>-Différence d'altitude trop faibles entre éléments normalement différenciables</i> <i>-Éléments à l'altitude négative</i>	Incertain	Par des mesures terrain
Discrimination des éléments du relief sur le MNH <i>-Non apparition des rangs de caféiers</i> <i>-Couvert forestier continu mal restitué</i> <i>-Arbres isolés oubliés</i> <i>-Choix de l'algorithme de stéréoscopie</i> <i>-Précision du calage</i>	Incertaine	Par photointerprétation en considérant différents types de sursol
Utilisation des indices de texture les plus adaptés <i>-Taille optimale de fenêtre</i> <i>-Problèmes liés à la texture Pléiades (bande verticale régulière)</i>	Incertaine	-
Traitements radiométriques sur le triplet Pléiades <i>-Pas de conversion entre la réflectance TOA et TOC</i> <i>-Influence de la radiométrie sur la stéréoscopie</i>	Négligeable	-
Segmentation et classification		
Sous-segmentation d'objets <i>-Limites floues entre objets de nature différentes</i> <i>-Résolution pas assez importante</i>	Critique	Indices de sur/sous-segmentation (basés sur DICE par exemple)
Sur-segmentation d'objets <i>-Validité des indices de textures sur des segments trop petits</i> <i>-Résolution trop importante</i>	Incertaine	
Choix des classes <i>-Classes trop larges (ex : Classe Vivrier)</i> <i>-Systèmes cultureaux difficiles à classifier avec certitude</i> <i>-Proximité trop importante entre classes</i>	Critique	Validation (matrices de confusion, probabilités de succès)
Jeu d'apprentissage de la segmentation <i>-Taille, équilibre et surface</i> <i>-Image d'origine (worldview/Pléiades)</i>	Critique	
Algorithmique <i>-Paramétrisation</i>	Incertaine	