

# Table des matières

---

<b>Résumé.....</b>	<b>3</b>
<b>Abstract .....</b>	<b>4</b>
<b>Remerciements .....</b>	<b>5</b>
<b>Table des matières .....</b>	<b>9</b>
<b>1 Introduction .....</b>	<b>14</b>
1.1 Contexte général : l'hétérogénéité des surfaces continentales.....	14
1.2 Cadre de l'étude.....	16
1.3 But de la thèse .....	18
1.4 Plan de la thèse.....	19
<b>2 Analyse de la variabilité spatiale des surfaces continentales : état de l'art et théorie multifractale .....</b>	<b>20</b>
2.1 Observations satellitaires et analyse d'images.....	20
2.1.1 Télédétection des surfaces continentales.....	20
2.1.1.1 Définition et principe de la télédétection .....	20
2.1.1.2 La télédétection pour l'Observation de la Terre .....	21
2.1.1.3 Les différents capteurs spatiaux et leurs applications.....	23
2.1.2 Méthodes usuelles d'analyse et de traitement d'images satellites .....	26
2.1.2.1 Assimilation de données .....	26
2.1.2.2 Algorithmes de classification .....	28
2.1.2.3 Méthodes de segmentation .....	32
2.1.3 Texture et analyse multi-échelle.....	34
2.1.4 Méthodes multifractales : contexte et intérêt.....	38
2.1.4.1 L'invariance d'échelle des phénomènes turbulents .....	39
2.1.4.2 Application aux surfaces continentales.....	40
2.2 Théorie des processus multifractals .....	42
2.2.1 Des objets fractals aux processus multifractals .....	42
2.2.1.1 Vocabulaire : échelle et résolution .....	42
2.2.1.2 Notion de fractale géométrique.....	44
2.2.1.3 Invariance d'échelle statistique.....	45
2.2.1.4 Processus multifractals .....	47
2.2.2 Les cascades multiplicatives .....	50
2.2.2.1 Principe de construction.....	50
2.2.2.2 Exemples de modèles.....	51
2.2.3 Multifractales Universelles .....	54
2.3 Simulation et analyse de Multifractales Universelles .....	56
2.3.1 Simulateur de champs multifractals .....	57

2.3.1.1	<i>Principe général</i> .....	57
2.3.1.2	<i>Exemples de simulations multifractales</i> .....	61
2.3.2	Description des estimateurs statistiques .....	63
2.3.2.1	<i>Spectre de puissance : détection de l'invariance d'échelle</i> .....	64
2.3.2.2	<i>Fonctions de structure : mise en évidence du caractère non-conservatif</i> .....	66
2.3.2.3	<i>Moments statistiques : propriétés multifractales</i> .....	68
2.3.3	Méthodologie générale d'analyse multi-échelle .....	71
<b>3</b>	<b>Analyse multi-échelle d'un algorithme de désagrégation déterministe d'humidité du sol : DisPATCH</b> .....	<b>74</b>
3.1	Introduction .....	74
3.1.1	Variabilité spatiale de l'humidité du sol .....	74
3.1.2	Apport de la télédétection pour le suivi de l'humidité du sol .....	76
3.1.3	Désagrégation spatiale pour l'étude fine échelle de l'humidité du sol .....	78
3.1.3.1	<i>Les différentes méthodes de désagrégation de l'humidité</i> .....	78
3.1.3.2	<i>Intérêt et évaluation de la méthode DisPATCH</i> .....	83
3.1.4	Etudes statistiques multi-échelles de l'humidité du sol .....	84
3.2	Cas d'étude et données .....	86
3.2.1	Processeur C4DIS : vers une couverture globale de l'humidité désagrégée .....	86
3.2.2	Produits d'entrée du C4DIS .....	87
3.2.2.1	<i>Les données globales d'humidité du sol SMOS</i> .....	87
3.2.2.2	<i>Les données auxiliaires MODIS</i> .....	88
3.2.2.3	<i>Autres données auxiliaires</i> .....	89
3.2.3	Produits désagrégés d'humidité du sol .....	89
3.2.4	L'algorithme DisPATCH .....	91
3.2.5	Zone d'étude .....	93
3.2.5.1	<i>L'étude de l'humidité du sol en Australie</i> .....	93
3.2.5.2	<i>Le bassin du Murray Darling : une vaste région aux propriétés climatiques variées</i> .....	95
3.2.6	Prétraitements réalisés sur les produits satellites .....	95
3.3	Résultats .....	98
3.3.1	Spectres de puissance : mise en évidence de deux régimes d'échelle pour l'humidité désagrégée .....	98
3.3.2	Fonctions de structure : confirment le degré d'intégration de l'humidité désagrégée et des données auxiliaires .....	102
3.3.3	Moments statistiques : application du modèle des Multifractales Universelles .....	104
3.4	Discussion .....	108
3.4.1	Impact des facteurs environnementaux sur les propriétés statistiques multi-échelles de l'humidité .....	108
3.4.1.1	<i>Des facteurs agissant à différentes échelle spatiales</i> .....	108
3.4.1.2	<i>Une rupture en lien avec les propriétés d'échelle de la pluie</i> .....	109
3.4.1.3	<i>Les effets saisonniers sur la variabilité spatiale de l'humidité</i> .....	110
3.4.2	Effet de l'algorithme de désagrégation sur les propriétés statistiques multi-échelles de l'humidité .....	113
3.4.2.1	<i>Mise en évidence d'un seul régime d'échelle pour les températures de brillance : cas de la mission AACES-2</i> .....	113

3.4.2.2	<i>Suivi des propriétés multi-échelles au sein de l'algorithme DisPATCh : implémentation d'une version simplifiée de la méthode</i>	115
3.5	Conclusion	121
<b>4</b>	<b>Caractérisation de données multispectrales à haute résolution spatiale par analyse multifractale</b>	<b>126</b>
4.1	Introduction	126
4.1.1	Apport des données multispectrales pour l'étude des surfaces continentales	126
4.1.1.1	<i>Reflectances de surface : principe et intérêt</i>	126
4.1.1.2	<i>Les capteurs optiques pour l'observation de la Terre</i>	129
4.1.2	Analyse de l'hétérogénéité spatiale des images optiques	131
4.1.3	Apport de la correction atmosphérique dans l'étude de la dynamique temporelle des propriétés d'échelle	135
4.1.3.1	<i>Composition de l'atmosphère et impact sur les réflectances de surface</i>	135
4.1.3.2	<i>Méthodes de correction atmosphérique</i>	137
4.2	Cas d'étude et données	141
4.2.1	Zone d'étude	141
4.2.1.1	<i>La région Sud-Ouest</i>	141
4.2.1.2	<i>L'Observatoire Spatial Régional</i>	142
4.2.1.3	<i>Sélection d'une zone d'étude dans le Gers</i>	143
4.2.2	Produits Sentinel-2	144
4.2.2.1	<i>La mission Sentinel-2 : pour un suivi à haute résolution spatiale et temporelle des surfaces continentales</i>	144
4.2.2.2	<i>Les bandes spectrales de l'imageur MSI</i>	145
4.2.2.3	<i>La chaîne globale de prétraitement des produits optiques</i>	146
4.2.2.4	<i>Les produits de l'étude : réflectances et indices optiques</i>	147
4.2.3	La chaîne de correction atmosphérique MAJA	148
4.2.3.1	<i>Description générale et intérêt</i>	148
4.2.3.2	<i>L'algorithme</i>	149
4.2.4	Prétraitements réalisés sur les images provenant de THEIA	154
4.3	Résultats	156
4.3.1	Comportement multi-échelle moyen : mise en évidence des régimes d'échelle et impact de la longueur d'onde	156
4.3.1.1	<i>Identification des gammes d'échelles</i>	156
4.3.1.2	<i>Estimation et comparaison des exposants d'échelle moyens</i>	158
4.3.2	Dynamique temporelle des propriétés d'échelle	166
4.3.2.1	<i>Cycle saisonnier fine échelle des réflectances de surfaces</i>	166
4.3.2.2	<i>Dynamique temporelle fine échelle des indices optiques</i>	170
4.4	Discussion	173
4.4.1	Mise en évidence des possibles limites de performance de capteurs optiques	173
4.4.1.1	<i>Une rupture fine échelle indépendante du temps et de la surface observée</i>	173
4.4.1.2	<i>Impact de la Fonction de Transfert de Modulation sur les propriétés statistiques fine échelle des réflectances de surface</i>	176
4.4.1.3	<i>Modélisation de la rupture fine échelle à partir d'une simulation de champ multifractal</i>	178

4.4.2	Des régimes d'échelles en lien avec l'hétérogénéité spatiale des surfaces agricoles	181
4.4.2.1	Des régimes aux propriétés multi-échelles distinctes	181
4.4.2.2	La parcelle comme échelle limite entre deux régimes	184
4.4.2.3	Une dynamique saisonnière liée aux cycles de cultures	186
4.4.2.4	Des gammes d'échelles qui évoluent selon la dynamique de la surface	187
4.4.2.5	Le lien entre occupation du sol et propriétés multi-échelles : tests sur d'autres types de surface	190
4.4.2.6	Simulation simplifiée d'une surface agricole	191
4.5	Conclusion	195
<b>5</b>	<b>Conclusion générale et perspectives</b>	<b>198</b>
5.1	L'algorithme DisPATCh en Australie	198
5.1.1	Synthèse des résultats	198
5.1.2	Perspectives	199
5.2	Les données Sentinel-2 dans la région Sud-Ouest	201
5.2.1	Synthèse des résultats	201
5.2.2	Perspectives	202
5.3	Bilan général	204
	<b>Références bibliographiques</b>	<b>207</b>
	<b>Liste des figures</b>	<b>233</b>
	<b>Liste des tableaux</b>	<b>239</b>
	<b>ANNEXES</b>	<b>241</b>
	Annexe A : Simulation de champs multifractals anisotropes	241
	Annexe B : Analyse de champs multifractals anisotropes	242
	Annexe C : Exemple d'application de l'algorithme de segmentation sur le spectre du champ multifractal <i>Rsimu</i>	243
	Annexe D : Gammes d'échelles utilisées pour l'analyse multifractale des produits DisPATCh	244
	Annexe E : Séries temporelles des paramètres <i>Hx</i> et <i>Hy</i> obtenus à partir des produits DisPATCh sur la période Juin-Décembre 2010	245
	Annexe F : Spectres de puissance des produits de Température de Brilliance AACES-2, pour les deux polarisations H et V	246
	Annexe G : Produits désagrégés d'humidité du sol obtenus le 19 novembre 2010 selon notre <i>version simplifiée de DisPATCh</i> . Comparaison des deux cas utilisant en entrée soit une seule image SMOS ou soit quatre images SMOS sous-échantillonnées.	247



Annexe H : Gammes d'échelles utilisées pour l'analyse multifractale des produits Sentinel-2.....	248
Annexe I : Séries temporelles des paramètres multi-échelles $\alpha$ , $C1$ et $H$ obtenus à partir des réflectances Sentinel-2 pour les gammes <i>large</i> et <i>fine échelle</i> (Janvier-Décembre 2016) .....	249
Annexe J : Anomalies normalisées des séries temporelles de coefficients de détermination $R^2$ obtenus à partir des régressions linéaires sur les différents estimateurs statistiques (spectres, fonctions de structure et moments) correspondant à la bande B2 de Sentinel-2, sur la gamme <i>fine échelle</i> (Janvier-Décembre 2016) .....	251
Annexe K : Séries temporelles des paramètres $Hx$ et $Hy$ obtenus à partir des indices optiques Sentinel-2 (et bandes correspondantes) pour la gamme <i>fine échelle</i> (Janvier-Décembre 2016) .....	252
Annexe L : Modélisation de la Fonction de Transfert de Modulation d'un capteur optique à partir des caractéristiques de la lentille (diffraction) et du détecteur (échantillonnage).....	253
Annexe M : Impact de la FTM sur le spectre de puissance d'un champ multifractal – cas d'un champ agrégé à deux fois l'échelle initiale .....	254
Annexe N : Mise en évidence de propriétés anisotropes dans les réflectances Sentinel-2 du proche infrarouge .....	255
Annexe O : Application de l'Entropie Multi-échelle pour mettre en évidence les propriétés fractales d'images simulées .....	257

# 1 Introduction

---

## 1.1 Contexte général : l'hétérogénéité des surfaces continentales

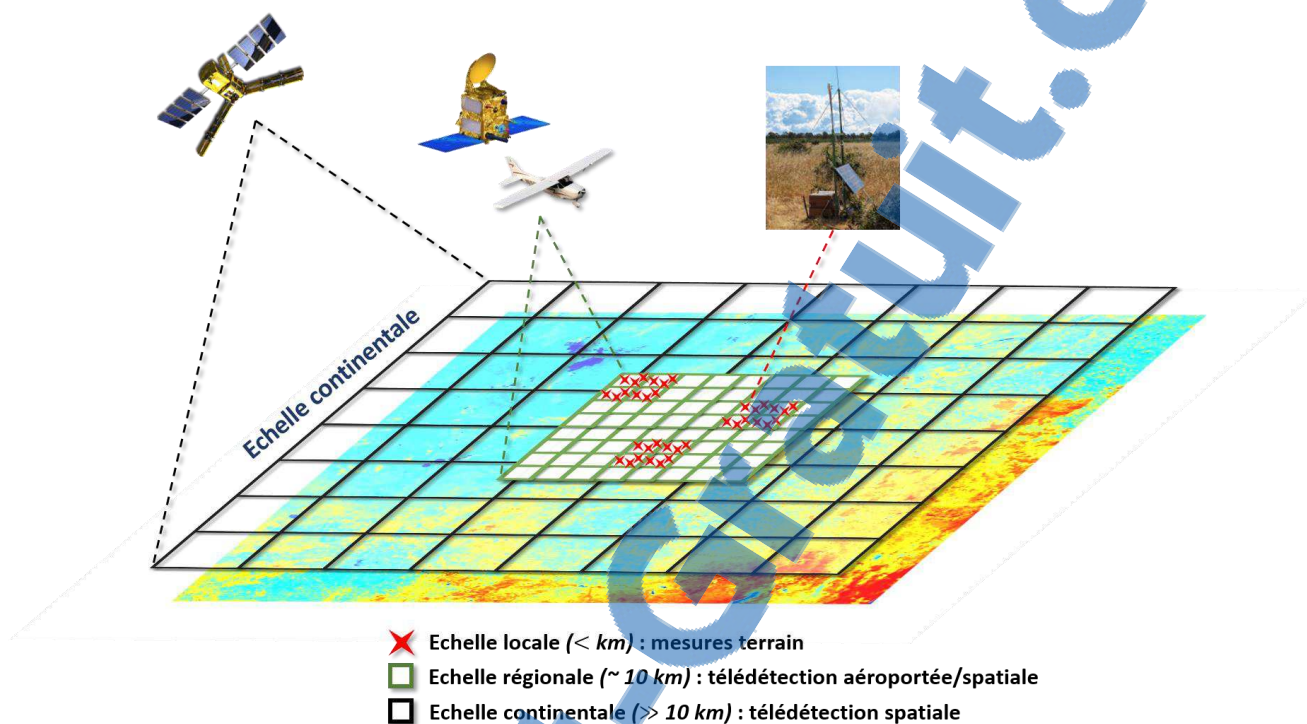
Les surfaces continentales sont régies par plusieurs processus géophysiques interagissant à diverses échelles spatiales. Ces mécanismes de surface peuvent être de type physique tel que les phénomènes de ruissellement, d'infiltration ou d'évaporation de l'eau mais également biophysique comme la répartition et l'évolution spatiale des populations d'espèces animales et végétales. Différentes variables ou facteurs influent sur ces processus de surface tels que la température de surface, l'humidité du sol, la végétation ou la topographie. Ces variables géophysiques ont un rôle majeur dans plusieurs composantes du système climatique telles que le cycle de l'eau et l'atmosphère, et sont directement reliées à d'autres facteurs quant à eux anthropiques tels que l'occupation du sol. Ainsi, l'étude du fonctionnement et de l'évolution des processus de surface s'avère primordiale dans le contexte actuel de réchauffement climatique. De plus, du fait de l'interaction directe entre l'homme et ces processus, leur connaissance est utile dans de nombreuses applications telles que l'aménagement du territoire, l'urbanisme, la gestion durable des ressources en eau, l'agronomie, ou encore la gestion des catastrophes naturelles.



*Figure 1.1 : Impact sur l'hétérogénéité des surfaces continentales de facteurs anthropiques tels que les cultures présentes sur l'image de gauche (Arizona, 17 Août 2019, satellite Venus), et de facteurs naturels comme le Delta du Yukon sur l'image de droite (Alaska, 29 Août 2017, satellite Sentinel-2)*  
[https://www.esa.int/ESA\\_Multimedia](https://www.esa.int/ESA_Multimedia)

Ainsi, l'hétérogénéité spatiale des surfaces continentales est due à un ensemble de facteurs naturels et anthropiques (fig.1.1) présents sur une large gamme d'échelles spatiales : de l'échelle continentale allant jusqu'à plusieurs centaines de kilomètres, à l'échelle plus locale des bassins versants et des parcelles agricoles située en-dessous du kilomètre. De plus,

en raison de leur couplage et interactions à différentes échelles spatio-temporelles, les phénomènes géophysiques, incluant le cas des surfaces continentales, présentent des dynamiques fortement non-linéaires (*feuille de route du Réseau National des Systèmes Complexes 2017*). Par exemple, des processus de surface relativement simples comme le ruissellement ou l'évaporation de l'eau, couplés aux processus atmosphériques tels que les précipitations, peuvent générer sur l'humidité du sol des comportements imprévisibles à long terme et conduisant à une structure spatialisée présentant une variabilité fortement non-linéaire à de multiples échelles.



**Figure 1.2 : Acquisition sur diverses échelles spatiales de l'hétérogénéité des surfaces continentales, au moyen de plusieurs technologies.**

Dans ce contexte, plusieurs techniques de mesure ont été développées pour permettre une étude complète sur une large gamme d'échelles spatiales (fig.1.2). D'une part, des campagnes terrain servent au suivi fin et localisé des surfaces grâce à des mesures in-situ. D'autre part, la télédétection spatiale et aéroportée permet d'accéder à la variabilité des processus sur de grandes échelles spatiales. Cependant, ces techniques complémentaires représentent l'hétérogénéité des variables observées sur une gamme d'échelles spécifique. Or, diverses études en écologie du paysage ont montré que les mesures d'hétérogénéité dépendaient de l'échelle spatiale à laquelle elles étaient réalisées (Wiens, 1989). Notamment, certaines caractéristiques des mesures telles que la résolution des données ou la taille de la zone d'étude pouvaient affecter ces mesures d'hétérogénéité (O'Neil et al., 1986). Ces travaux ont alors mené à plusieurs questionnements sur la notion d'échelle et son impact sur les données, et en particulier à s'interroger sur l'échelle de mesure la plus adaptée à telle ou telle étude (Gustafson, 1998).

Etant donné le nombre grandissant d'observations présentes à diverses échelles spatiales, les méthodes basées sur l'analyse multi-échelle peuvent fournir un moyen efficace pour décrire et mieux comprendre l'hétérogénéité des surfaces. En particulier, une possibilité consiste à s'intéresser à l'existence de lois d'échelles statistiques généralisant la notion de fractale géométrique ([Mandelbrot, 1975](#)). Cela permettrait de mettre en évidence des comportements d'échelle spécifiques, valables sur des intervalles continus d'échelles (ou "gammes d'échelles"), contribuant ainsi à caractériser les processus de surface selon une approche originale qui est peu souvent prise en compte dans les modèles actuels de surface.

## 1.2 Cadre de l'étude

Le travail de cette thèse consiste à proposer et à appliquer une méthode permettant de décrire et de mieux comprendre les comportements de variables de surface physiques et biophysiques sur plusieurs échelles. Pour cela, nous utiliserons le modèle des Multifractales Universelles ([Schertzer and Lovejoy, 1987](#)). Construit sur des procédures de cascades multiplicatives, ce modèle stochastique permet de caractériser l'ensemble des propriétés multi-échelles de processus aléatoires grâce à seulement trois paramètres. Initialement développé dans le domaine de la turbulence, il a servi à modéliser la variabilité de divers phénomènes atmosphériques tels que les précipitations ou les nuages. Plus récemment, des travaux portant sur l'étude de la végétation et de l'humidité du sol ([Lovejoy et al., 2008](#)) ont mis en évidence le potentiel des Multifractales Universelles pour caractériser les propriétés multi-échelles, complexes, de certains éléments de la surface.

Nous nous intéresserons dans cette thèse à deux cas d'études distincts, consistant à analyser différents produits de surface acquis par télédétection.

La première application portera sur l'étude multi-échelle de l'algorithme de désagrégation spatiale d'humidité du sol DisPATCh (Disaggregation based on Physical And Theoretical scale Change; [Merlin et al., 2008a](#); [Molero et al., 2016](#)). Développé au CESBIO (Centre d'Etudes Spatiales de la Biosphère), cet algorithme déterministe permet d'améliorer la résolution spatiale de données satellites d'humidité du sol SMOS (Soil Moisture and Ocean Salinity) de 40 km à 1 km. Pour cela, il combine les produits basse résolution fournis par SMOS à des données optiques/thermiques haute résolution (~ 1 km) mesurées par le capteur MODIS (MODerate resolution Imaging Spectroradiometer). En particulier, l'objectif de ce travail est d'étudier et de comparer les propriétés multifractales des produits d'entrée et de sortie de DisPATCh, afin de proposer une méthode de validation de l'algorithme en termes de comportement multi-échelle. Pour cela, nous appliquerons le modèle des Multifractales Universelles à chacun de ces produits afin de comparer sur un continuum d'échelles la variabilité de l'humidité désagrégée à celle des produits d'origine SMOS et MODIS (indice de

végétation et température de surface). Durant cette étude, nous utiliserons des données d'humidité journalières obtenues de juin à décembre 2010, sur la partie Sud-Est de l'Australie. Nous avons choisi l'Australie comme lieu d'étude en raison des nombreuses missions menées au cours des dernières années pour l'analyse de l'humidité du sol à partir de données terrain, aéroportées ou satellites.

Le deuxième cas d'étude consistera à analyser les propriétés multifractales de données multispectrales à haute résolution spatiale. Cela a pour objectif de montrer l'intérêt de l'approche multi-échelle pour caractériser des données multispectrales et pour mettre en évidence l'hétérogénéité des surfaces continentales. Pour cela, nous utiliserons les réflectances de surface acquises par le satellite Sentinel-2, dans diverses bandes spectrales, à une résolution de l'ordre de la dizaine de mètres. Nous analyserons également des indices optiques construits à partir de ces réflectances, rendant compte de l'état de la végétation et du niveau d'humidité du sol. De plus, grâce à la chaîne de traitement MAJA (MACCS-ATCOR Joint Algorithm; [Hagolle et al., 2010, 2015a](#); [Rouquié et al., 2017](#)) dont le développement a été initié par le CESBIO et CNES (Centre National d'Etudes Spatiales), nous bénéficierons de produits de surface corrigés des effets atmosphériques. Cela nous permettra d'identifier une série temporelle d'images Sentinel-2-MAJA sans nuages, acquises de janvier à décembre 2016, sur la région Sud-Ouest de la France. Cette région présente un intérêt de par la forte hétérogénéité spatiale de ses surfaces, liée aux effets combinés de facteurs anthropiques et naturels. Notamment, les surfaces agricoles, qui sont prépondérantes dans cette région, jouent un rôle majeur dans la structure spatiale et son évolution au cours des saisons. De plus, le fonctionnement et l'évolution des processus de surface bénéficient dans cette zone d'un suivi particulier grâce aux nombreux sites instrumentés de l'Observatoire Spatial Régional, porté par le CESBIO.

### 1.3 But de la thèse

Les travaux présentés dans ce manuscrit visent à apporter certaines informations nouvelles et complémentaires sur la variabilité spatiale de processus de surface au moyen d'une méthode multi-échelle statistique. L'objectif est de recenser et de caractériser les gammes d'échelles spatiales de chaque produit étudié pour lesquelles il y a des lois statistiques remarquables.

Par rapport à la littérature, nous souhaitons tout d'abord élargir les gammes d'échelles spatiales habituellement étudiées pour l'humidité du sol. Grâce à l'utilisation combinée des produits SMOS et DisPATCh, ce travail nous permettra d'avoir accès à la variabilité de l'humidité du sol sur une vaste gamme d'échelles allant du kilomètre au millier de kilomètres. Dans chaque cas d'étude, nous aurons la possibilité de comparer les comportements multi-échelles de diverses variables de surface acquises dans des conditions identiques, afin de mettre en évidence leur possible interaction sur des échelles spatiales variées. D'autre part, l'analyse de séries temporelles d'images permettra d'étudier l'évolution temporelle des propriétés multi-échelles, que nous pourrons relier aux variations saisonnières des processus en question. L'approche temporelle permettra ainsi de faire le lien entre nos résultats et les caractéristiques de la zone d'étude telles que l'occupation du sol ou les conditions météorologiques.

Enfin, ce travail pourra apporter certaines informations sur l'impact des méthodes d'acquisition et de combinaison de produits satellites sur les processus mesurés. En effet, nous verrons en quoi un algorithme de désagrégation peut affecter les propriétés multi-échelles de produits de télédétection. De plus, nous pourrons mettre en évidence l'effet des capteurs optiques sur les propriétés statistiques fine échelle des réflectances de surface. Cela permettra entre autre de déterminer les limites de performances de techniques de mesure ou méthodes combinatoires couramment utilisées en télédétection spatiale et dans les modèles de surface.

## 1.4 Plan de la thèse

Le chapitre 2 de ce manuscrit porte de manière générale sur l'analyse de la variabilité spatiale des surfaces continentales. Une première partie recense les diverses méthodes d'acquisition par satellite et de traitement d'image spécifiques à l'étude des processus de surface. La deuxième partie présente le formalisme des multifractales utilisé dans cette étude. Puis, une troisième partie décrit la méthodologie et les outils statistiques que nous avons appliqués dans cette thèse pour analyser le comportement multifractal d'une ou plusieurs images.

Le chapitre 3 concerne le premier cas d'étude de cette thèse portant sur l'analyse multi-échelle de l'algorithme de désagrégation d'humidité du sol DisPATCh. Les produits analysés ici ont été acquis en Australie, pendant la période Juin-Décembre 2010.

Dans le chapitre 4, nous exposons le second cas d'étude correspondant à l'analyse multifractale de données multispectrales Sentinel-2. Nous étudions ici des produits acquis sur la région Sud-Ouest de la France, plus particulièrement dans le département du Gers, durant la période Janvier-Décembre 2016.

Enfin, le chapitre 5 présente les conclusions et perspectives générales de ce travail.



## 2 Analyse de la variabilité spatiale des surfaces continentales : état de l'art et théorie multifractale

---

Dans ce chapitre, une première partie consistera en un état de l'art non technique recensant les diverses méthodes de télédétection et de traitements d'images utilisées à ce jour pour l'étude des surfaces continentales. En particulier, nous nous intéresserons aux méthodes dédiées à l'analyse de la variabilité spatiale des surfaces, notamment les outils d'analyse de texture et les méthodes multi-échelles comme les multifractales. Ensuite, une deuxième partie portera sur le formalisme théorique des multifractales sur lequel se base cette étude. Après avoir défini le concept de "fractal" et son utilisation en géophysique, nous présenterons les modèles multifractals développés et appliqués dans la littérature, avec une attention particulière portée sur le modèle des Multifractales Universelles (MU). Enfin, une troisième partie sera consacrée à la présentation de la méthodologie et des outils statistiques utilisés dans cette thèse pour analyser le comportement multifractal d'une ou plusieurs images.

### 2.1 Observations satellitaires et analyse d'images

Compte tenu de la forte hétérogénéité spatio-temporelle des surfaces continentales, la télédétection spatiale s'est avérée être un moyen indispensable pour réaliser un suivi à la fois régulier, local et global des processus physiques et biophysiques qui régissent ces surfaces. Les facteurs dont ils dépendent, tels que l'humidité des sols, la température de surface, la végétation ou la topographie, sont variables sur de larges gammes d'échelles auxquelles seuls les satellites peuvent accéder. Afin de rendre compte au mieux de l'évolution des surfaces et d'en étudier leur fonctionnement, un nombre grandissant de méthodes d'acquisition par satellite (télédétection par capteurs passifs/actifs) et d'analyse de données (algorithmes de traitements d'image) a été observé dans les cinquante dernières années.

#### 2.1.1 Télédétection des surfaces continentales

##### 2.1.1.1 Définition et principe de la télédétection

De manière générale, la télédétection consiste en l'acquisition d'informations sur des objets ou des phénomènes observés à partir de mesures effectuées à distance. Pour acquérir ces informations, la télédétection se base sur l'enregistrement et l'interprétation des rayonnements électromagnétiques émis ou réfléchis par la cible étudiée. Selon la longueur



d'onde dans laquelle ces rayonnements sont mesurés, diverses propriétés de la cible peuvent être identifiées comme sa composition, sa structure, son état, etc.

Les ondes électromagnétiques peuvent être définies sur une large gamme de longueurs d'onde correspondant au spectre électromagnétique (figure 2.1). Cette longueur d'onde  $\lambda$  s'exprime en mètres et est associée à la fréquence  $f$  du rayonnement telle que  $\lambda = c/f$  (avec  $c$  la vitesse de la lumière). Le spectre électromagnétique est centré sur le domaine du visible ( $0.4 < \lambda < 0.7 \mu m$ ), et s'étend des très courtes longueurs d'ondes ( $10^{-9} \mu m$ ) correspondant aux rayons cosmiques utilisés en astronomie (observation des rayonnements provenant de l'espace), jusqu'aux ondes radio ( $1 km$ ) utilisées en télécommunication. Dans le domaine de l'Observation de la Terre, les rayonnements mesurés se situent essentiellement dans la partie centrale du spectre électromagnétique c'est-à-dire l'ultraviolet (UV) proche ( $0.25 - 0.4 \mu m$ ), le domaine optique comprenant l'ensemble du visible et de l'infrarouge ( $0.4 \mu m - 1 mm$ ) et les micro-ondes ou hyperfréquences ( $1 mm - 100 mm$ ).




Figure 2.1 : Spectre électromagnétique

#### 2.1.1.2 La télédétection pour l'Observation de la Terre

Pour embarquer les capteurs servant à l'acquisition des rayonnements terrestres, deux grandes familles de plateformes sont utilisées. D'une part nous trouvons les plateformes se situant dans l'atmosphère, appelées "aéroportées". C'est vers la fin du 19<sup>ème</sup> siècle que les premières applications en télédétection ont été réalisées au moyen de ballons embarquant des capteurs optiques. Notamment, les premières photographies aériennes ont été acquises en 1844 via le ballon Nadar. Cela a été utile en particulier pour le lever de plans topographiques ou hydrographiques. Le premier avion transportant un capteur optique fera son apparition quelques années plus tard : il s'agit de l'avion WRIGHT, en 1909. L'aviation a permis un développement important de la photographie aérienne, en particulier par son utilisation intensive comme moyen de reconnaissance pendant la 1<sup>ère</sup> guerre mondiale.

L'avion reste la plateforme aéroportée la plus utilisée à ce jour, bien que d'autres moyens comme l'hélicoptère ou plus récemment le drone permettent de fournir des images avec une précision de plus en plus importante. En effet, de par leur distance relativement faible de la surface ( $< 5$  km), ces plateformes aéroportées permettent de fournir des images à très haute résolution spatiale (de l'ordre du centimètre, fig.2.2) et pour un coût relativement faible (par comparaison aux satellites). Cependant, les produits fournis couvrent des zones restreintes limitant donc à des études plutôt locales des phénomènes terrestres ( $\sim 10$  km x 10 km).

Ce n'est que depuis les années 60 que les capteurs sont embarqués sur des satellites artificiels placés en orbite autour de la Terre. Ces plateformes spatiales observent de grandes surfaces (fig.2.2), pouvant atteindre l'échelle continentale (plusieurs milliers de kilomètres), et ont l'avantage de permettre une acquisition systématique et répétitive. Ainsi, la répétitivité (ou résolution) temporelle des données satellites est assurée, pouvant être de l'ordre du journalier pour certaines missions spatiales. Cela est un atout majeur pour l'étude des processus physiques et biophysiques des surfaces continentales qui sont variables sur de larges échelles à la fois spatiales et temporelles. En Observation de la Terre, les satellites sont placés sur des orbites polaires héliosynchrones situées entre environ 500 et 1000 km d'altitude. Ainsi, pour un même point au sol, ce type d'orbite permet un passage du satellite à la même heure solaire. L'orbite géostationnaire est également utilisée en télédétection, mais par des satellites météorologiques pour lesquels la même zone est observée, ne permettant pas de couverture globale de la Terre. Ces orbites ont l'avantage de couvrir de très grandes étendues, avec des données disponibles de manière presque continue. En revanche, la résolution spatiale est plus faible et ne permet pas d'étudier la variabilité fine échelle des surfaces continentales.




*Figure 2.2 : Images acquises dans le visible (composition colorée) en France près d'Agen : à partir d'un avion à gauche, et à partir d'un satellite (SPOT-5) à droite (d'après Pelletier, 2016).*

### 2.1.1.3 Les différents capteurs spatiaux et leurs applications

Selon le domaine spectral dans lequel les ondes sont acquises, différentes techniques de mesure existent, impliquant différents types de capteurs embarqués sur les satellites. Dans cette sous-partie, nous allons présenter brièvement les grandes familles de capteurs utilisés en télédétection spatiale, en se focalisant sur les techniques d'acquisition relatives à l'étude des surfaces continentales. Ces techniques seront illustrées par quelques applications pour lesquelles elles sont couramment utilisées. Le but ici n'est pas de donner une liste exhaustive des capteurs et méthodes de télédétection, mais d'avoir une vision globale de la télédétection des surfaces. Pour plus de détails, nous invitons le lecteur à se référer aux travaux cités ci-dessous ou aux parties plus détaillées de ce manuscrit (voir section 3.1.2 pour une description des radiomètres en micro-ondes passives servant à la détection de l'humidité du sol et section 4.1.1 pour plus de détails sur les capteurs optiques et leurs applications).

En Observation de la Terre, il existe ainsi différents types de capteurs pour étudier de manière complémentaire les surfaces continentales. D'une part, nous trouvons les capteurs passifs qui mesurent les rayonnements naturels. Ces capteurs peuvent soit mesurer les rayonnements émis par le Soleil (source 1 dans la figure 2.3) et ensuite réfléchis par la surface de la Terre, soit directement mesurer les radiations propres de la Terre ou d'un objet situé sur la surface (source 2). Dans le cas des rayonnements solaires réfléchis sur la Terre, les capteurs permettent d'observer la manière dont les surfaces continentales rétrodiffusent ces rayonnements dans le domaine optique, correspondant aux longueurs d'onde du visible ( $0.4 - 0.7 \mu m$ ), proche infrarouge ( $0.8 - 1 \mu m$ ) et moyen infrarouge ( $1 - 10 \mu m$ ). Par exemple, les surfaces principalement composées de végétation réfléchiront fortement dans le proche infrarouge, et celles très humides réfléchiront davantage dans le moyen infrarouge. Ces caractéristiques permettent entre autre de générer des cartes d'occupation du sol ou de suivre l'état de stress des plantes (section 4.1.1). Les images fournies ont l'avantage d'être riches en information de type formes et contours (fig.2.4), souvent utilisées dans les algorithmes de segmentation. Pour ce qui est des rayonnements directement émis par la Terre, les capteurs mesurent ceux-ci dans des longueurs d'onde situées au-delà du moyen infrarouge. Par exemple, dans l'infrarouge thermique ( $10 - 15 \mu m$ ), les radiations mesurées permettent d'avoir accès à la température de la surface et d'estimer la capacité d'évapotranspiration de la végétation, ou encore de détecter les feux de forêts et les éruptions volcaniques (Sobrino and Del Frate, 2016). De même, les émissions de la surface dans le domaine des micro-ondes ou hyperfréquences ( $1 mm - 100 mm$ ) permettent de détecter et de mesurer le taux d'humidité du sol, et ce à travers la végétation (section 3.1.2).

1. Domaine optique (spectre solaire)
2. Infrarouge thermique
3. Télédétection active (radar)




*Figure 2.3 : Différentes méthodes d'acquisition du rayonnement électromagnétique pour l'étude des surfaces continentales (d'après Kergomard, 1990).*

D'autre part, les capteurs actifs mesurent l'énergie réfléchie par une cible au sol en envoyant une onde électromagnétique vers la surface (source 3, fig.2.3). Cette technique utilise donc une source artificielle de rayonnement qui, selon la manière avec laquelle elle est rétrodiffusée, donne une information sur les propriétés de la surface. Par exemple, les capteurs RADAR (RADioDetection And Ranging) émettent une impulsion micro-ondes qui est sensible à la géométrie de l'objet rencontré au sol, donnant par exemple des informations sur la rugosité et la texture du sol (fig2.4). En agriculture, cela permet de discriminer différents types de cultures (Bargiel and Hermann, 2011), et d'en estimer leur rendement au moyen de modèles agro-météorologiques (Ameline et al., 2018; Baup et al., 2015). D'autres applications utilisent également cette propriété des "radars", comme l'étude de l'occupation du sol en zones urbaines (Wu et al., 2015) ou alors la classification des forêts (Simard et al., 2000). De plus, l'impulsion micro-onde est également sensible au contenu en eau de la surface, permettant ainsi d'étudier l'évolution de l'humidité du sol à des échelles relativement fines (El Hajj et al., 2018; Wagner et al., 2009). Un principal atout de ces méthodes d'acquisition est qu'elles sont insensibles à l'atmosphère, dont les nuages qui peuvent s'avérer très contraignants dans le cas de la télédétection passive par capteur optique (cf. section 4.1.3). Ainsi, les radars sont opérationnels indépendamment des conditions climatiques et d'illumination (acquisition possible de jour comme de nuit). En revanche, cette technique de mesure implique des prétraitements complexes avant d'obtenir une information utilisable, car, de par sa forte sensibilité à la géométrie du sol, la méthode d'acquisition radar peut



engendrer des distorsions ainsi que du bruit dans l'image ("speckle") (Kergomard, 1990). Parmi les capteurs actifs, nous pouvons citer également les LIDARs (LightDetection And Ranging) qui émettent et reçoivent un faisceau de lumière. Le laser émis par le satellite peut se situer dans le domaine spectral du visible, de l'infrarouge ou de l'ultraviolet proche. Basée sur une mesure de distance entre le capteur et la cible au sol, cette technique a été initialement utilisée pour estimer et étudier la topographie (Mallet and Bretar, 2009). Comparé au radar, le lidar peut fournir une information avec une résolution spatiale très élevée pouvant atteindre 10 points de mesure par mètre carré et avec une erreur de localisation inférieure à la dizaine de centimètres (Nuninger et al., 2008). De nombreuses études sur l'estimation de la hauteur de canopée ont été réalisées grâce au lidar, permettant notamment de fournir des cartes précises de classification de la forêt (Dubayah and Drake, 2000) ou de déterminer la structure 3D de la végétation (Bergen et al., 2009). Cette technique de mesure est également utilisée en étude de l'atmosphère, pour analyser les propriétés des nuages et des aérosols (Winkeral., 2010).



*Figure 2.4 : Images acquises sur le Cambodge : par capteur optique en composition colorée depuis le satellite Sentinel-2 à gauche, et par capteur radar depuis Sentinel-1 à droite. L'emprise de l'image radar inclut celle de l'image optique (pointillés rouges). De plus, la coloration de l'image radar est obtenue en montrant les deux polarisations VV et VH, c'est-à-dire en plaçant dans les canaux RGB de l'image un pourcentage du signal reçu en polarisation verticale (VV) et horizontale (VH) lorsque celui-ci a été initialement émis en position verticale. Les zones de végétation présentant beaucoup de rugosité sont en vert clair, les zones lisses sont en violet (d'après <http://www.pixalytics.com>).*

Nous venons de voir qu'un certain nombre de méthodes complémentaires existent à ce jour pour acquérir des informations sur les surfaces continentales. **Ces méthodes fournissent un nombre considérable d'observations aux caractéristiques différentes.** En effet, selon leurs applications, les satellites d'observation de la Terre peuvent avoir une répétitivité temporelle allant de la quinzaine de jours (Landsat) au jour (Formosat), et peuvent embarquer des capteurs dont les résolutions spectrales peuvent varier d'une bande d'acquisition (radar ou micro-ondes passives) à plusieurs dizaines de bandes (MODIS). De même, la résolution spatiale des acquisitions est très variable d'une technologie à l'autre : celle-ci peut être de l'ordre du mètre voire du centimètre dans le cas des capteurs lidars et optiques et passer à plusieurs dizaines de kilomètres pour les radiomètres en micro-ondes passives. **Ainsi, diverses méthodes ont été développées pour permettre d'analyser et d'extraire au mieux l'information riche et conséquente qui est acquise par les satellites.**

## 2.1.2 Méthodes usuelles d'analyse et de traitement d'images satellites

Dans cette sous-partie, nous présentons les méthodes couramment utilisées en télédétection pour traiter et analyser les images satellites de manière à extraire des informations sur la variabilité spatiale des processus de surface. Nous n'aborderons pas l'étape relative aux prétraitements des données, qui est une phase préliminaire indispensable à l'application des méthodes que nous présenterons dans une section dédiée (voir section 4.2.2.3 pour plus de détails sur les prétraitements). Ici, nous présentons en particulier les techniques d'assimilation de données dans les modèles de surfaces, les algorithmes de classification permettant de produire des cartes d'occupation du sol et enfin, les méthodes de segmentation utilisées pour améliorer les performances des algorithmes habituels, notamment en classification. Une sous-partie dédiée exclusivement aux techniques d'analyse de texture et multi-échelles est présentée en section 2.1.3.

### 2.1.2.1 Assimilation de données

Une des finalités principales de l'étude des surfaces continentales est la modélisation de ses processus biophysiques. Cela est possible grâce à des modèles de surface qui simulent la variabilité spatiale et temporelle des processus présents dans le milieu "sol-couvert-atmosphère", et suivant certaines conditions environnementales ([Tupin et al., 2014](#); [Sellers et al., 1986](#)). Ces conditions sont définies grâce à la mesure de variables physiques telles que la pluie, la température ou l'humidité du sol. A partir de ces données "réelles" placées en entrée du modèle, ce dernier fournit des données "synthétiques" simulées. Pour prendre en compte la forte hétérogénéité spatiale et temporelle des surfaces, les modèles nécessitent un nombre important de données d'entrée. A l'inverse des mesures terrain ponctuelles par nature, la télédétection spatiale peut fournir facilement un jeu de données conséquent et varié, dont

les résolutions spatiales et temporelles sont adaptées pour la modélisation à des échelles régionales. Néanmoins, l'utilisation de ces données dans les modèles de surface ne se fait pas de manière directe. Diverses méthodes permettent de prendre en compte les observations dans les modèles telles que les techniques d'inversion, de calibration, d'optimisation, etc. Nous allons regrouper ici l'ensemble de ces techniques sous les termes "d'assimilation de données". Ces méthodes diffèrent essentiellement en fonction du rôle des données satellites dans le modèle, ainsi que du niveau de sophistication de l'approche.

Selon la classification proposée par [Bach and Mauser \(2003\)](#), nous pouvons trouver quatre approches principales d'assimilation de données satellites :

(1) La première consiste à transformer les données de télédétection brutes, c'est-à-dire les rayonnements acquis par le satellite, en paramètres spatialisés de la surface tels que l'élévation du sol ou l'occupation du sol. Cette technique est la plus souvent utilisée, et implique l'utilisation d'algorithmes de traitement spécifiques tels que ceux utilisés en classification par exemple (voir section suivante). Dans ce cas, les données satellites ne nécessitent pas d'avoir une forte répétitivité temporelle, étant donnée la faible dynamique des paramètres de surface obtenus (occupation du sol faiblement variable au cours du temps par exemple).

(2) Une autre approche consiste à utiliser les données satellites pour mettre à jour les variables dynamiques du modèle. Cela permet de forcer le système décrit par le modèle à rester dans un état réaliste défini par les variables mesurées. A titre d'exemple, nous pouvons citer le modèle IFFS (Integrated Flood Forecast System; [Bach et al., 2000](#)) qui assimile des données radars d'humidité du sol et optiques d'occupation du sol pour modéliser et prévoir les inondations. De même, le modèle SAFY-WB (Simple Algorithm For Yield model combined with a Water Balance; [Ameline et al., 2018](#); [Duchemin et al., 2015](#)) combine des données radars et optiques rendant compte de l'état de la végétation pour estimer et prévoir le rendement des cultures.

(3) Les mesures satellites peuvent également servir à la recalibration des paramètres d'initialisation du modèle. D'une certaine manière, cette méthode est comparable à l'approche 2, c'est-à-dire avec pour fonction principale de mettre à jour le modèle. Ici, il s'agit de corriger ou d'ajuster par optimisation les valeurs des variables d'état calculées par le modèle lorsque celles-ci dérivent des valeurs obtenues à partir des mêmes variables mais provenant cette fois-ci des acquisitions satellites. Suivant cette approche, [Burke et al. \(1998\)](#) ont tiré parti des rayonnements acquis par micro-ondes passives pour ajuster les propriétés hydrauliques du sol, lesquelles étaient utilisées en tant que paramètres d'initialisation d'un modèle de bilan hydrique et énergétique du sol.

(4) Enfin, une dernière approche est l'inversion de modèle. Dans ce cas, la méthode consiste à appliquer la procédure inverse de l'approche 3, c'est-à-dire de simuler les données satellites

d'entrée du modèle (réflectances de surface, micro-ondes radar) à partir des variables d'état du modèle comme l'humidité du sol, la végétation, etc. Cette méthode permet de corriger le modèle, en ajustant ses variables d'état suivant la différence entre données satellites mesurées et données satellites inversées ou synthétiques. La différence principale avec l'approche 3 est que la correction ou l'ajustement du modèle se fait ici à l'extérieur du modèle en effectuant la comparaison de données d'entrée réelles et synthétiques (telles que des réflectances ou des données micro-ondes) et non à l'intérieur du modèle comme le fait l'approche 3 en comparant variables d'état réelles et synthétiques (humidité du sol ou végétation). Un exemple de modèle d'inversion est le modèle GeoSail ([Bach et al., 2001](#)), qui simule les réflectances de canopée. Ce dernier a contribué, de par son utilisation combinée avec le modèle de surface PROMET-V ([Mauser and Schädlick, 1998](#)), à montrer comment l'hétérogénéité des paramètres de la végétation (biomasse, hauteur, etc.) pouvait être estimée par assimilation et inversion de données satellites optiques et radars.

Certaines approches vont même au-delà et visent à reconstruire entièrement les équations des modèles à partir des observations sans hypothèse a priori ([Mangiarotti et al. 2012, 2014, 2019](#)). D'autres approches combinent plusieurs de ces approches, telles que les méthodes d'assimilation-inversion ([Mangiarotti and Schoenauer, 2011](#)) qui optimisent à la fois les paramètres et les trajectoires au sein des modèles ([Mangiarotti et al., 2010](#)).

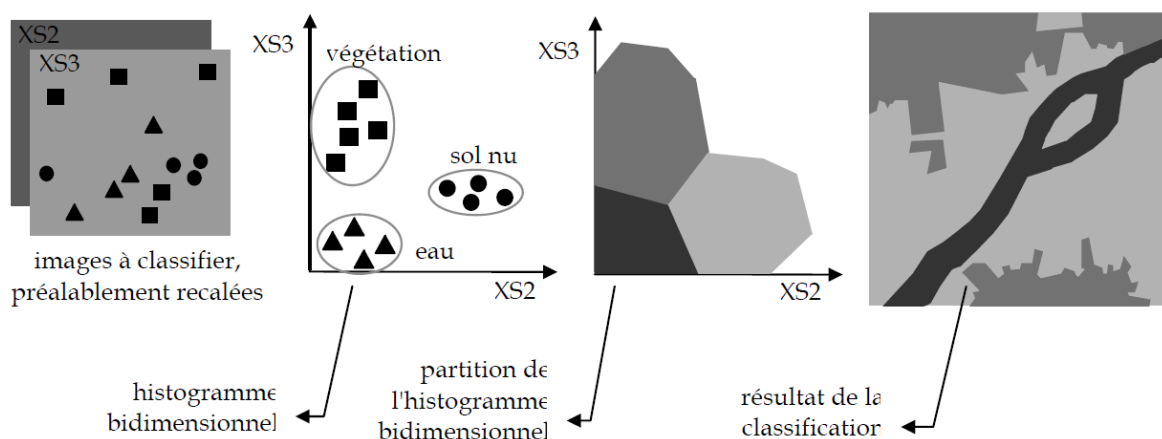
#### 2.1.2.2 Algorithmes de classification

La classification est une procédure par laquelle chaque objet de l'image – pixels ou régions (regroupement de pixels) – se voit attribuer une étiquette permettant de le différencier des autres objets de l'image. En télédétection des surfaces continentales, la classification des images satellites a pour objectif de retrouver l'occupation du sol. Très utilisée dans le domaine de la cartographie ([Hansen and Loveland, 2012; Huang et al., 2010](#)), cette procédure permet de rendre compte de l'hétérogénéité des surfaces, en mettant en évidence les différents facteurs, à la fois anthropogéniques et naturels, qui jouent sur cette variabilité spatiale.

Les algorithmes de classification ont pour fonction de regrouper de manière plus ou moins automatique les objets de l'image ayant les mêmes caractéristiques. Ces caractéristiques peuvent être de type radiométrique, basé sur la valeur des pixels, ou de type contextuel, c'est-à-dire selon l'organisation spatiale de ces valeurs. Avant chaque classification, l'objet à classer est représenté dans un espace à N dimensions également appelé espace des caractéristiques ou espace des primitives, où chaque dimension correspond à une caractéristique. Les réflectances acquises par les différentes bandes spectrales des capteurs optiques sont un exemple de primitives qui peuvent permettre de regrouper les différents éléments de la surface. La figure 2.5 illustre le principe de classification à partir d'images acquises dans deux bandes spectrales (nommées ici XS2 et XS3) qui sont nos deux



primitives de type radiométrique. La représentation des éléments de la scène dans l'espace à deux dimensions (histogramme bidimensionnel) permet d'extraire les différents types de sol (végétation, sol nu, eau) pour produire une carte d'occupation du sol. D'autres primitives sont également utilisées telles que les indices optiques issus de la combinaison de plusieurs bandes, ou alors des primitives contextuelles comme l'orientation, la distance, l'aire ou l'inclusion des objets (Inglada, 2015).




**Figure 2.5 : Principe de la classification appliquée aux images satellites (d'après Polidori, 2006).**

Divers algorithmes existent pour réaliser la classification de données satellites. Ils diffèrent selon plusieurs critères, lesquels seront choisis en fonction de l'application, des performances nécessaires, de la résolution spatiale des données, du type d'images, etc. Nous distinguons d'une part les algorithmes supervisés et non-supervisés, qui diffèrent selon leur utilisation ou non d'éléments étalons déjà classés (pixels dont l'occupation du sol est connue) pour réaliser la classification des pixels "inconnus". La méthode des K-means est une classification non-supervisée souvent appliquée en traitement d'images (Burrough et al., 2000). Cet algorithme nécessite peu d'information de l'utilisateur, seulement le nombre de classes (k) dans lesquelles regrouper les objets de l'image. Les algorithmes non-supervisés ont l'avantage de permettre une classification sans connaissance au préalable des classes. Cependant, les traitements peuvent être longs lorsque le jeu de données est conséquent, ce qui est souvent le cas en télédétection. De plus, grâce aux nombreuses études réalisées dans le domaine de la cartographie (Lu and Weng, 2007), les propriétés physiques des différents types de sol sont déjà connues et répertoriées, impliquant généralement une connaissance des classes présentes dans l'image.


C'est pourquoi les classifications utilisées en cartographie sont souvent de nature supervisée. Par exemple, le SVM (Support Vector Machine; Kim et al., 2003) et le maximum de vraisemblance (Dean and Smith, 2003) sont couramment utilisés grâce à leur robustesse et

leur disponibilité dans les logiciels de traitement d'images satellites. La classification par maximum de vraisemblance fait partie d'une sous-catégorie d'algorithmes appelés "paramétriques", impliquant que les paramètres statistiques soient représentatifs des données observées pour réaliser la classification. Cette condition peut être contraignante dans certaines situations, notamment lors de l'utilisation de primitives non radiométriques telles que la texture et des données exogènes comme la topographie, la distance à une route ou la densité de population. L'algorithme SVM, quant à lui, a l'avantage d'être non-paramétrique et de fournir une classification avec peu d'erreur tout en nécessitant un minimum d'échantillons étalons (fig.2.6).



*Figure 2.6 : Classification à six classes réalisée par SVM à partir de réflectances de surface (d'après Inglada, 2015).*

De manière générale, les algorithmes non-paramétriques comme le SVM sont bien adaptés à la classification de paysages complexes (Foody, 2002). Nous pouvons citer des procédures plus sophistiquées basées sur des arbres de décision, tel que le Random Forest (Defries et al., 1998; Pal, 2005) ou les réseaux de neurones (Kavzoglu and Mather, 2003; Paola and Schowengerdt, 1995). Ces algorithmes sont connus pour être très performants, adaptables à différents types de données et également efficaces pour prendre en compte des jeux de données importants et de nature différente. La figure 2.7 présente un exemple de classification effectuée par Random Forest sur la ville de Toulouse à partir de données optiques Landsat-8. Une nouvelle approche de classification basée sur la théorie du chaos a également été introduite récemment permettant de prendre en compte l'instabilité des comportements dynamiques de façon déterministe (Mangiarotti et al., 2018).



**Figure 2.7 : Classification réalisée par Random Forest à partir des réflectances de surface (Landsat-8) acquises le 22/06/2013 sur la ville de Toulouse (d'après Pelletier, 2016).**


Une autre manière de distinguer les algorithmes de classification est de le faire par leur approche orientée pixel, contexte ou objet. La plupart des méthodes sont basées sur une approche pixel : le pixel est alors considéré comme le seul type d'objets à classer, et cela est réalisé principalement à partir de primitives radiométriques et spectrales. Cependant, l'approche pixel peut générer des erreurs de classification (pixels mal classés) lorsque la résolution des images est grossière – engendrant des pixels qui combinent les propriétés de plusieurs types de surfaces (Cracknell, 1998) – ou lorsque la résolution est, à l'inverse, élevée créant des variations radiométriques importantes dans l'image (bruit) dues à la forte hétérogénéité des surfaces (Dean and Smith, 2003). L'approche contextuelle utilise l'environnement (le voisinage) de chaque pixel pour réaliser la classification. Les primitives utilisées correspondent à des estimateurs statistiques informant sur la texture de l'image (voir section 2.1.3). Le modèle de Markov est une procédure contextuelle fréquemment utilisée en traitement d'image, qui a montré l'intérêt de prendre en compte l'information spatiale afin d'améliorer les performances de classification pour l'occupation du sol (Magnussen et al., 2004; Puissant et al., 2005). Enfin, l'approche orientée objet peut s'avérer efficace pour la classification de données à haute voire très haute résolution spatiale, notamment en cartographie de zones urbaines (Thomas et al., 2003) ou encore pour identifier les différentes espèces d'arbres présentes dans des milieux à végétation dense (Wang et al., 2004). Cette approche consiste à réaliser une classification, non pas sur des pixels, mais sur des groupes de pixels (objets) de l'image. Pour cela, une étape préalable de segmentation est appliquée pour identifier ces objets (voir section suivante). Nous pouvons citer la méthode eCognition, qui est couramment utilisée en télédétection des surfaces continentales (Benz et al., 2004).



### 2.1.2.3 Méthodes de segmentation

La segmentation consiste à partitionner l'image en régions homogènes ou objets selon un critère prédéfini. A la différence de la classification qui affecte une étiquette de classe à chaque pixel, la segmentation fournit une étiquette de région (ou identifiant région) pour chaque objet détecté. Dans le domaine de l'Observation de la Terre, cette méthode est souvent utilisée pour améliorer les performances de classification en cartographie ([Inglada, 2015](#)). Elle peut être utilisée avant classification dans le cas d'une classification objet, ou alors après classification pour supprimer les pixels mal classés de l'image.

Il existe deux grandes familles d'approches pour réaliser une segmentation : les approches régions, qui vont regrouper les pixels selon des critères de similarité, et les approches contours qui vont plutôt chercher à détecter les discontinuités dans l'image correspondant à des transitions abruptes d'intensité ([Tupin et al., 2014](#)). Parmi les approches régions, la méthode de segmentation la plus simple est la croissance de région ([Zucker, 1976](#)). Il s'agit d'un algorithme local, c'est-à-dire que le point de départ de la segmentation se fait depuis des pixels appelés "graines", à partir desquels des régions sont construites (fig.2.8). Cela se fait en fusionnant les pixels voisins selon des critères de similarité radiométrique, géométrique ou statistique. Cette méthode est par exemple implémentée dans l'algorithme eCognition servant à la classification objet d'images satellitaires ([Benz et al., 2004](#)). La croissance région est très efficace, car rapide d'utilisation, mais peut poser certaines difficultés dans le choix des graines à l'initialisation.



*Figure 2.8 : Segmentation réalisée par croissance de région à partir des réflectances acquises dans une bande spectrale. Les régions détectées sur l'image de droite semblent correspondre aux routes sur l'image originale (d'après [Inglada, 2015](#)).*

Des méthodes également basées sur l'approche région mais plus globales permettent d'éviter ce problème d'initialisation. Nous pouvons citer la ligne de partage des eaux ([Ogor and Kpalma, 1996](#)), qui utilise le gradient de l'image pour la partitionner. L'image est alors comparable à une surface topographique que l'on remplirait d'eau, mettant ainsi en évidence des "bassins" (c'est-à-dire les régions de l'image). Cette méthode a été notamment utilisée pour déterminer l'occupation du sol à partir d'images optiques provenant du satellite SPOT ([Sellami et al., 2008](#)). L'algorithme du Mean Shift ([Comaniciu and Meer, 2002](#)) est basé sur une méthode comparable à la classification par K-means (section 2.1.2.2), à la différence qu'il considère, en plus de la localisation radiométrique, une localisation spatiale des pixels de l'image. Ainsi, les pixels ayant les mêmes propriétés radiométriques mais étant trop éloignés dans l'image (selon un rayon prédéfini) ne seront pas regroupés dans la même région (fig.2.9). Cet algorithme a été appliqué en classification de la végétation ([Ponti, 2013](#)), notamment en cartographie de l'étendue et de l'intensification des rizières à partir d'images Landsat ([Kontgis et al., 2015](#)).



*Figure 2.9 : Segmentation réalisée par Mean Shift à partir des réflectances acquises dans le visible (d'après [Inglada, 2015](#)).*

Dans les cas des approches contours, une première étape consiste à détecter les contours de l'image. Généralement, cette étape est faite en identifiant les maxima de la dérivée du signal, elle-même estimée à partir du gradient. Jusque-là, la méthodologie s'apparente beaucoup à la segmentation par ligne de partage des eaux. Cependant, les approches contours diffèrent en particulier par l'application d'une deuxième étape, dite de "clôture", qui prolonge et connecte les contours entre eux ([Tupin et al, 2014](#)). Pour cela, plusieurs techniques sont utilisées telles que la transformée de Hough ([Bicego et al., 2003](#)) ou les modèles de contours actifs ([Kas et al., 1988](#)). Ces dernières méthodes restent tout de même peu utilisées en télédétection, où les formes des objets recherchés sont très hétérogènes et moins connues que dans d'autres domaines comme l'imagerie médicale par exemple.


### 2.1.3 Texture et analyse multi-échelle

Pour étudier les surfaces continentales, nous venons de voir que diverses méthodes d'analyse d'images satellites ont été développées, mettant à profit à la fois les propriétés spectrales (radiométriques) mais aussi spatiales des images. **En effet, la caractérisation de la variabilité spatiale peut fournir une information complémentaire et non négligeable dans la description des paysages** (Gustafon, 1998). Ainsi, nous présentons dans cette sous-partie les différentes méthodes dédiées à l'analyse de texture. Cette dernière consiste à étudier l'arrangement spatial des intensités dans l'image, donnant des informations sur le contraste, la rugosité, la similarité, la forme, l'orientation, etc. (Rosenfeld, 1982; Tamura et al., 1978). En Observation de la Terre, cette approche est utilisée notamment dans les algorithmes de classification par approche contextuelle (section 2.1.2.2), **mais également pour étudier le comportement multi-échelle de certains processus acquis par télédétection** (Lovejoy et al., 2008b; Ryu and Famiglietti, 2006; Usowicz et al., 2019).

Différentes méthodes ont été développées pour analyser la texture des images. Humeau-Heurtier et al. (2019) ont recensé ces méthodes, en les regroupant en classes aux approches différentes. Nous allons reprendre brièvement leur classification, en se focalisant sur les méthodes utilisées en Observation de la Terre. Ces classes et les méthodes correspondantes sont récapitulées dans le tableau 2.1, accompagnées de quelques exemples d'application.

Dans un premier temps, nous trouvons les approches statistiques qui extraient les propriétés statistiques de la distribution spatiale des niveaux d'intensité dans l'image. Parmi les méthodes les plus connues, nous pouvons citer la matrice de co-occurrence, également appelée GLCM (Grey Level Co-occurrence Matrix Approach) qui consiste à étudier les relations statistiques des niveaux de gris (corrélation, homogénéité, etc.) pour des pixels situés à des positions variables dans l'image (Haralick et al., 1973). Bien qu'elle nécessite beaucoup d'espace mémoire, cette méthode est simple et rapide d'utilisation. Par exemple, appliquée sur des images radars, elle a démontré de bonnes performances pour identifier différentes textures de la banquise (Soh and Tsatsoulis, 1999). La méthode du variogramme est également une approche statistique couramment appliquée aux images, notamment en Observation de la Terre. Celle-ci consiste à tracer l'évolution de la variance  $\gamma$  de la différence entre des observations en fonction de leur distance  $h$  dans l'image (fig.2.10). La pente de la courbe, calculée en coordonnées logarithmiques, donne des informations sur la rugosité de l'image. Une pente élevée correspondra à un signal lisse et autocorrélé, alors qu'une pente faible traduira la présence d'un signal plus bruité, avec des transitions brutales. De plus, si cette pente est constante, le signal présente une texture similaire d'une échelle à l'autre. Le signal est alors qualifié d'auto-similaire ou de fractal. Ainsi, le variogramme est souvent utilisé pour étudier le comportement multi-échelle de processus de surfaces comme l'humidité du

sol (Usowicz et al., 2019; Ryu and Famiglietti, 2006), pour analyser la structure de la végétation notamment la forêt (St-Onge and Cavayas, 1995) ou encore pour améliorer les performances de traitement en classification (Chica-Olmo and Abarca-Hernandez, 2000).




*Figure 2.10 : Présentation schématique du variogramme. Des termes particuliers sont utilisés pour les diverses sections de la courbes : la portée est la gamme des distances  $h$  où il y a autocorrélation (pente non nulle), le palier correspond à la variance maximale atteinte pour les grandes échelles de l'image.*

Les approches structurelles consistent quant à elle à décomposer la texture de l'image en éléments (objets, lignes) et à analyser leur arrangement spatial comme leur orientation, élongation, compacité, répétition, etc. Ces méthodes se basent essentiellement sur des outils de morphologie mathématique (Haralick et al., 1987) servant à extraire les éléments de l'image par détection de contours notamment. En télédétection, ces méthodes sont utilisées principalement en segmentation pour la classification d'images (cf. section 2.1.2.3). Bicego et al. (2003) ont par exemple appliqué ce type d'approches pour identifier avec précision les contours des routes dans des images optiques aériennes. Les approches structurelles fournissent de bons résultats pour des images à textures régulières. En revanche, elles ne sont pas appropriées aux images présentant des signaux fortement aléatoires, ce qui est généralement le cas des processus de surface comme l'humidité, la température ou la végétation.

Les approches par "transformée" ne présentent pas de contraintes vis-à-vis des signaux aléatoires. Celles-ci consistent à représenter l'image dans un espace dont le système de coordonnées est étroitement relié aux caractéristiques de la texture, c'est-à-dire la fréquence ou l'échelle spatiale. La transformée de Fourier décompose l'image en une somme de plusieurs sinusoïdes aux fréquences différentes et décrit de cette manière le comportement de l'image dans l'espace des fréquences. Cela permet de mettre en évidence certaines caractéristiques multi-échelles de processus de surface comme la fractalité,

l'anisotropie ou les ruptures d'échelle (Kim and Barros, 2002b; Lovejoy et al., 2008b). De plus, cette méthode permet également d'identifier et de caractériser les structures répétitives, comme par exemple les vignes observées par images aériennes (fig.2.11; Delenne et al., 2006). Un inconvénient de cette transformée est qu'elle ne fournit pas la localisation des propriétés de texture au sein de l'image. Une alternative est la transformée en ondelettes qui permet d'étudier la variabilité spatiale de l'image par application d'une ondelette (petite oscillation non forcément sinusoïdale) ayant subi différentes translations et dilatations (Daubechies, 1990). Basée sur un formalisme comparable à celui de la transformée de Fourier, cette méthode permet d'observer le comportement multi-échelle de l'image (à chaque dilatation de l'ondelette correspond une échelle spatiale) mais également son comportement spatial (translations dans l'image), et ce de manière simultanée. A titre d'exemple, la transformée en ondelettes a été appliquée sur des images satellites à très haute résolution spatiale ( $< 1$  m) afin d'améliorer la classification de la végétation (Lucieerand van der Werff, 2007).



*Figure 2.11 : Image aérienne de vignes (gauche) ainsi que le module de sa transformée de Fourier (droite). Le pic central correspond aux basses fréquences de l'image, sur lesquelles est répartie la majeure partie de l'énergie. Les pics situés autour du pic central sont directement liés à la présence de vignes dans l'image. La direction formée par ces pics et le pic central correspondent à la perpendiculaire des rangs de vignes, de même que la distance entre un pic et le pic central est associée à la taille des inter-rangs (d'après Delenne et al., 2006).*

Une autre manière d'extraire les propriétés de texture d'une image est d'utiliser des modèles mathématiques. Parmi les plus connus, nous pouvons citer le modèle de Markov, aussi appelé champ aléatoire de Markov (Markov Random Field). Ce dernier consiste à représenter de manière empirique l'intensité de chaque pixel à partir de celle des pixels voisins (Blake et al., 2011). Ce modèle est couramment utilisé en classification contextuelle (cf. section 2.1.2.2), dans diverses applications telles que l'identification de différents types de plantes par exemple (AlSuwaidi et al., 2017). De même, les modèles fractals permettent de



caractériser la complexité des images ([Mandelbrot, 1967](#)), qui est en lien direct avec la texture du signal analysé. Ces méthodes consistent à extraire la dimension fractale des images, informant sur leur rugosité. Plusieurs manières permettent d'extraire cette dimension. La plus ancienne est la méthode du "box-counting" qui a été utilisée notamment en segmentation ([Costal et al., 2012](#); [Keller et al., 1989](#)) ainsi que pour la caractérisation d'images optiques hyperspectrales ([Qiu et al., 1999](#)). L'analyse spectrale peut également estimer cette dimension fractale et contribuer à décrire des paysages naturels ([Pentland, 1984](#)).

Les différentes approches présentées jusqu'ici sont bien connues dans le domaine du traitement d'image et sont appliquées depuis un certain nombre d'années. De nouvelles approches sont apparues récemment, présentant des performances intéressantes et une façon différente d'aborder l'analyse de texture. Il s'agit des approches par apprentissage et des approches par entropie. La première famille d'approches comprend des méthodes d'apprentissage par réseaux de neurones. Initialement utilisées en vision par ordinateur ([Lawrence et al., 1997](#)), ces méthodes ont prouvé leur excellente capacité à représenter la texture des images ([Cimpoi et al., 2015](#)). Fondés sur des algorithmes d'apprentissage supervisé, les réseaux de neurones permettent l'extraction de caractéristiques de haut niveau à partir de données brutes, et ce de manière automatique. Ils ont notamment montré leur intérêt pour proposer une classification détaillée des textures du sol ([Ozuysal, 2018](#)). Ensuite, les approches par entropie consistent à réaliser une mesure d'entropie directement sur l'image, informant sur l'irrégularité et la complexité du signal. Ces méthodes ont fait leur preuve dans le domaine biomédical avec l'analyse de séries temporelles ([Costa et al., 2002](#)). Facile à implémenter et fondées sur des aspects théoriques solides, l'approche par entropie a ensuite été appliquée à l'analyse d'images. Plus particulièrement, l'entropie d'échantillon ([Richman and Moorman, 2000](#)) a prouvé son intérêt pour caractériser la texture d'images diverses ([Silva et al., 2016](#)). Une variante multi-échelle de cette méthode a été proposée par [Silva et al. \(2018\)](#) : l'entropie multi-échelle. Cette méthode permet de révéler l'évolution de la complexité, et ainsi de la texture, en fonction de l'échelle spatiale, servant par exemple à améliorer la classification des textures ([Silva et al., 2018](#)). De plus, [Nogueira \(2017\)](#) a mis en évidence le lien entre les propriétés fractales de données géophysiques (vitesse du vent) et l'entropie multi-échelle. Bien que ces résultats aient été appliqués sur des signaux à une dimension, cela montre le potentiel de l'entropie multi-échelle à révéler le degré de complexité présent dans les processus géophysiques. En revanche, un des inconvénients des approches par apprentissage et par entropie est leur temps de calcul. Cela peut s'avérer problématique dans le cas d'images satellites dépassant souvent le million de pixels.

APPROCHES	METHODES	APPLICATIONS
STATISTIQUES	Matrice de co-occurrence	Cartographie de la banquise par radar (Soh et al., 1999)
	Variogramme	Etude de l'humidité du sol par micro-ondes passives (Usowicz et al., 2019)
STRUCTURELLES	Morphologie mathématique	Identification de routes par images aériennes (Bicego et al., 2003)
TRANSFORMEES	Fourier	Etude multi-échelle des surfaces par images optiques (Lovejoy et al., 2008)
	Ondelettes	Classification de la végétation par images optiques (Lucieer and van der Werff, 2007)
MODELES	Champ de Markov	Classification de plantes par images optiques (AlSuwaidi et al., 2017)
	Fractales	Caratérisation d'images optiques hyperspectrales (Qiu et al., 1999)
APPRENTISSAGE	Réseaux de neurones	Classification de la texture du sol (Ozuysal, 2018)
ENTROPIE	Entropie d'échantillon	Etude de la complexité et de l'irrégularité (Silva et al., 2016)
	Entropie multi-échelle	Evaluation et classification des textures (Silva et al., 2018)

*Tableau 2.1 : Récapitulatif des différentes méthodes utilisées en analyse de texture d'images (d'après Humeau-Heurtier et al., 2019).*

#### 2.1.4 Méthodes multifractales : contexte et intérêt

Dans les sections précédentes, nous avons présenté les méthodes utilisées en télédétection pour étudier la variabilité spatiale au sein des images. Celles-ci peuvent se baser sur les propriétés radiométriques des images ou sur leurs propriétés contextuelles, analysant l'environnement spatial de chaque pixel. Certaines méthodes d'analyse de texture comme le variogramme, la transformée de Fourier ou l'entropie multi-échelle étudient **la manière avec laquelle les signaux présents dans l'image, et en particulier leurs statistiques, évoluent en fonction de l'échelle spatiale. L'analyse multifractale fait partie de ces méthodes "statistiques multi-échelles"**. Initialement développée dans le domaine de la turbulence puis appliquée pour la modélisation de la pluie et plus récemment aux surfaces continentales, l'approche multifractale s'inscrit dans un contexte historique et théorique solide, **ce qui la rend intéressante pour l'étude de processus fortement hétérogènes sur plusieurs échelles spatiales, comme ceux des surfaces continentales.**

#### 2.1.4.1 L'invariance d'échelle des phénomènes turbulents

Durant le siècle dernier, de nombreuses études ont mis en évidence les propriétés d'invariance d'échelle ou propriétés fractales des processus géophysiques. Cela fut initialement observé en turbulence par [Richardson \(1922\)](#). Ce dernier constata que les phénomènes turbulents pouvaient être décrits par un procédé en cascade qui transfère l'énergie cinétique des grandes échelles vers les petites échelles. A partir de cette approche, des modèles statistiques de la turbulence ont été proposés tels que la loi de [Kolmogorov \(1941\)](#) qui décrit le comportement d'un flux d'énergie homogène en fonction de l'échelle  $l$  :

$$\Delta v = \varepsilon^{1/3} l^{1/3}$$

2.1

où  $\Delta v$  sont les incréments de vitesse caractérisant le flux et  $\varepsilon$  est un taux de dissipation d'énergie cinétique (soit le flux d'un moment d'ordre 2 de la vitesse). Cette équation en loi puissance exprime la dépendance des propriétés statistiques du flux à l'échelle à laquelle ce dernier est représenté. On parle alors de loi d'invariance d'échelle, caractérisée par un exposant d'échelle (ici défini à  $1/3$ ) qui est invariant d'une échelle à l'autre, alors que les incréments de vitesse dépendent quant à eux de l'échelle. Notons que l'exposant d'échelle  $1/3$  est une valeur caractéristique des processus turbulents ([Schmitt et al., 1993](#)).

Par la suite, cette loi a été adaptée et généralisée à des flux d'énergie inhomogènes ([Kolmogorov, 1962](#); [Oboukhov, 1962](#); [Yaglom, 1966](#)). Des modèles multi-échelles tels que les cascades multiplicatives (section 2.2.2) ont ainsi été développés pour reproduire les propriétés d'invariance d'échelle en se basant sur la théorie fractale ([Mandelbrot, 1967](#)). Parmi les plus connus, nous pouvons citer le modèle des Multifractales Universelles ([Schertzer and Lovejoy, 1987](#)) ou encore le modèle Log-Poisson ([She and Levêque, 1994](#)). De nombreuses applications de ces modèles multifractals ont été réalisées en turbulence ([Parisi and Frisch, 1985](#); [Schmitt et al., 1993](#)), ce qui a ensuite mené à divers travaux portant sur la dynamique de processus atmosphériques présentant des propriétés fractales tels que les nuages (fig.2.12) ([Lovejoy and Schertzer, 2010a](#); [Lovejoy et al., 2001](#); [Siebesma and Jonker, 2000](#); [Tessier et al., 1993](#)) et les précipitations ([de Montera et al., 2009](#); [Lovejoy and Schertzer, 2008](#); [Verrier et al., 2010, 2011](#)).

#### 2.1.4.2 Application aux surfaces continentales

Grâce à son étude de la côte Britannique, [Mandelbrot \(1967\)](#) a mis en évidence les propriétés fractales de la topographie (fig.2.12), en montrant que le périmètre des traits de côte dépendait de l'échelle à laquelle il était calculé, et ce suivant une loi puissance caractérisée par un exposant constant. Ainsi, il a montré que l'invariance d'échelle était également une caractéristique des phénomènes non-turbulents. Par la suite, d'autres travaux de recherche ont confirmé les propriétés d'invariance d'échelle de la topographie ([Mark and Aronson, 1984](#); [Roy et al., 1987](#); [Shelberg et al., 1983](#)). Ces premières études réalisées sur les surfaces continentales ont consisté principalement à estimer et à étudier la dimension fractale, mettant ainsi en évidence les propriétés d'invariance d'échelle des surfaces au sens géométrique. De même, certains travaux portant sur l'analyse fractale de réflectances de surface acquises par satellite ont montré l'intérêt de cette approche pour mettre en évidence le haut degré de complexité des surfaces continentales ([De Cola, 1989](#); [Lam, 1990](#); [Qiu et al., 1999](#)).



**Figure 2.12 : Phénomènes géophysiques aux propriétés fractales tels que les nuages (gauche) et la topographie (droite). Dans ces deux exemples, chaque partie de l'entité observée présente des propriétés similaires à l'ensemble.**

L'analyse des propriétés multifractales des surfaces, cette fois-ci au sens statistique, n'a été réalisée que plus tard. Les premières applications de modèles multifractals ont été menées en topographie. Celles-ci ont évalué les propriétés multifractales de la topographie des continents de manière générale ([Gagnon et al., 2006](#); [Lavallée et al., 1993](#)), des volcans ([Laferrière and Gaonac'h, 1999](#)), et plus récemment des exo-planètes ([Landais et al., 2019](#)). Ensuite, un certain nombre d'études multifractales ont été menées pour caractériser les propriétés des sols ([Kravchenko et al., 1999](#); [Xie et al., 2010](#)). Des travaux ont notamment analysé la distribution multifractale d'éléments géochimiques du sol ([Cheng, 2000](#)) ainsi que la répartition spatiale des cours d'eau et systèmes de bassins versants ([Cheng et al., 2001](#)).

D'autres travaux ont mis en évidence les propriétés multifractales de l'humidité du sol acquise par capteurs aéroportés (Kim and Barros, 2002b; Ko et al., 2016; Mascaro et al., 2010; Oldak, 2002) et par mesures terrain (Biswas et al., 2012). Les premières analyses multifractales de réflectances de surface acquises par satellites ne sont apparues que récemment, avec notamment les travaux de Lovejoy et al. (2008b) et Alonso et al. (2017) qui ont montré le comportement multifractal d'images optiques obtenues dans différentes bandes spectrales ainsi que d'indices de végétation et d'humidité du sol.

De manière générale, bien que les méthodes d'analyse multi-échelle aient montré leur intérêt certain pour étudier l'hétérogénéité spatiale des surfaces, **relativement peu d'études multifractales de produits de télédétection ont été réalisées à ce jour dans le domaine des surfaces continentales**. Mise à part la topographie qui bénéficie d'un certain nombre d'études, les applications citées ci-dessus correspondent à quelque chose près à l'ensemble des travaux que l'on peut recenser dans ce domaine. Cela est en partie lié au contexte historique des multifractales initialement développées pour modéliser la turbulence et la pluie, expliquant le nombre important d'études dans ce domaine. De plus, certains éléments de la surface tels que la végétation (chapitre 3) ou de l'atmosphère tels que les nuages (chapitre 4) peuvent impacter significativement les rayonnements acquis par satellite, contribuant ainsi à rendre plus difficile l'analyse des variables des surfaces continentales, ce qui peut aussi expliquer le nombre limité d'analyses multifractales de variables comme l'humidité du sol par exemple. Le tableau 2.2 résume les principaux travaux de la littérature portant sur l'analyse multifractale des variables étudiées dans cette thèse : l'humidité du sol par micro-ondes passives (chapitre 3) et les réflectances optiques (chapitre 4).

	Variable	Capteur	Gamme d'échelles	Outils/modèle d'analyse multi-échelle	Référence
MICRO-ONDES PASSIVES	Humidité du sol	ESTAR (aéroporté)	[ 1 – 25 ] km	MULTIFRACTALES LOG-POISSON *	Mascaro et al., 2010
			[ 1 – 250 ] km	Outils d'analyse statistique: variance, spectres, moments **	Kim and Barros, 2002
			[ 0.5 – 20 ] km	Outils d'analyse statistique: variance, spectres, moments **	Oldak et al., 2002
REFLECTANCES OPTIQUES	Indice d'humidité du sol	MODIS (spatial)	[ 0.5 – 25 ] km	MULTIFRACTALES UNIVERSELLES *	Lovejoy et al., 2008
	Indice de végétation				
	Bandes spectrales (R,V,B,PIR,MIR)				
	Indice de végétation	Ikonos 2 - Landsat 7 (spatial)	[ 0.05 – 10 ] km	METHODE DES MOMENTS **	Alonso et al., 2017
	Bandes spectrales (R,V,B,PIR)				

\* Voir section 2.2 pour une définition des modèles

\*\* Pas de paramétrisation

**Tableau 2.2 : Présentation des principaux travaux portant sur l'analyse multifractale de l'humidité du sol et des réflectances de surface acquises par télédétection.**

## 2.2 Théorie des processus multifractals

Dans cette partie, nous présentons le formalisme théorique des multifractales. Après avoir brièvement introduit les notions d'invariance d'échelle géométrique et statistique, lesquelles seront illustrées par des exemples d'objets et de processus fractals, nous présenterons les modèles multi-échelles de cascades multiplicatives utilisés en géophysique. Les propriétés statistiques sur lesquelles se basent ces modèles seront également décrites. En particulier, nous détaillerons les équations et paramètres d'échelle du modèle des Multifractales Universelles (Schertzer and Lovejoy, 1987) utilisé dans ces travaux de thèse.

### 2.2.1 Des objets fractals aux processus multifractals

Comme nous venons de le voir dans les sections précédentes, le concept de dimension fractale a été utilisé dans de nombreux travaux portant sur l'analyse multi-échelle et la modélisation des processus géophysiques. Le terme "fractal" fait référence à toute entité (série temporelle ou champ aléatoire à deux ou trois dimensions) dans laquelle chaque partie présente des propriétés similaires à l'ensemble. On parle d'autosimilarité géométrique dans le cas d'objets ou d'ensembles mathématiques, ou d'autosimilarité statistique dans le cas de processus aléatoires. Dans les deux cas, la structure de l'entité fractale est dite "invariante par changement d'échelle".

#### 2.2.1.1 Vocabulaire : échelle et résolution


Par souci de clarté, nous voulons avant tout définir les termes de "résolution" et "d'échelle" *au sens du formalisme mathématique fractal*. En effet, bien que leur signification soit proche de celle habituellement utilisée par les géophysiciens, notamment en télédétection, elle peut être sensiblement différente et pourrait mener à certains contresens dans la suite de ce manuscrit.

Si l'on considère un espace de dimension (géométrique)  $D$  (soit  $D = 1$  pour une série temporelle ou un transect spatial,  $D = 2$  pour une image), discrétisé sur un ensemble d'intervalles ou de pixels, la résolution  $\lambda$  de toute entité fractale peut être définie comme le nombre d'intervalles (ou de pixels) présents le long d'une dimension de l'espace. Dans le cas d'une image satellite de taille 4 x 4 pixels, la résolution de l'entité fractale est donc égale à  $\lambda = 4$  (fig.2.13). Inversement proportionnelle à la résolution, l'échelle  $l$  est associée à la taille d'un intervalle ou d'un pixel et se définit selon  $\lambda$  :

$$l = \frac{L}{\lambda}$$

2.2

où  $L$  est l'échelle la plus large, correspondant à la taille du domaine le long d'une dimension donnée (exprimée en mètres ou en kilomètres). Dans le cas de notre image satellite  $4 \times 4$ , l'échelle vaut  $l = L/4$ , soit la taille d'un pixel élémentaire. Si nous agrégeons maintenant notre image sur des grilles constituées de nouveaux pixels deux fois plus larges (ou de surface quatre fois plus grande), la résolution de l'image sera prise égale à  $\lambda = 2$ , et l'échelle vaudra  $l = L/2$ .



**Figure 2.13 : Illustration des concepts de résolution et d'échelle à partir d'une entité fractale à deux dimensions (image satellite).**


De cette manière, chaque entité fractale est définie sur un continuum de résolutions (ou échelles) qui s'étend de la résolution la plus fine (soit  $\lambda = L/l_0$ ) à laquelle est associée l'échelle la plus réduite, soit la taille d'un pixel élémentaire (ici notée  $l_0$ ), à la résolution la plus grossière ( $\lambda = 1$ ) correspondant à l'échelle la plus large ( $l = L$ ).

En télédétection, la résolution spatiale d'un capteur désigne la capacité de ce dernier à distinguer deux points de mesure voisins. Cette caractéristique dépend du pas d'échantillonnage du capteur, définissant la distance au sol entre chaque mesure, mais également de la précision ou largeur au sol des mesures ("tâches" plus ou moins étendues selon le type de capteur). Ainsi, d'un point de vue du formalisme multifractal, la résolution spatiale des capteurs ne correspond pas directement à la résolution  $\lambda$  (nombre de pixels) mais plutôt à l'échelle  $l$  (taille de chaque pixel). Par conséquent, dans la suite de ce manuscrit, nous ferons attention à bien distinguer la résolution  $\lambda$  utilisée dans les modèles fractals de la résolution servant à caractériser les capteurs spatiaux.



### 2.2.1.2 Notion de fractale géométrique

Initialement, les premiers objets aujourd'hui qualifiés de fractals ont été introduits à la fin du 19<sup>ème</sup> siècle en géométrie par la création d'objets mathématiques ayant des propriétés "inhabituables" dépassant celles de la géométrie euclidienne. Construits selon une procédure itérative, ces ensembles ont servi de contre-exemple aux propriétés mathématiques des objets plus habituels et réguliers. Par exemple, l'ensemble de Cantor (1872) est remarquable car il est à la fois non dénombrable et négligeable au sens de la mesure de Lebesgue, ce qui physiquement le rend à la fois "continu" (équipotent à  $\mathbb{R}$ ) et de longueur nulle (fig.2.14.a). De même, le "flocon" de Von Koch a la particularité d'être défini par une courbe continue en tout point et de n'admettre de tangente en aucun point (fig.2.14.b). Ces deux objets ont pour caractéristique commune de présenter des propriétés d'invariance d'échelle géométrique, c'est à dire que l'ensemble de chaque objet ressemble à certaines de ses parties à un zoom près. Cela peut se voir facilement sur la figure 2.14.a où chaque partie de l'ensemble de Cantor est représentée par deux segments placés côte à côte, que ce soit aux échelles maximales (segments situés sur les lignes supérieures de l'objet) ou à l'échelle minimale (segments situés aux extrémités des branches inférieures).



**Figure 2.14 : Exemple d'objets fractals : (a) ensemble de Cantor de dimension fractale  $D_f = 0.63$  et (b) "flocon" de Von Koch avec  $D_f = 1.26$**

De cette manière, ces objets sont caractérisés par une dimension non entière, appelée plus tard par Mandelbrot "dimension fractale" (Mandelbrot, 1967). Cette dimension caractéristique des objets fractals peut être estimée de diverses manières (Falconer, 2004). Il existe plusieurs définitions telles que la dimension de Hausdorff (la plus rigoureuse, mais aussi l'une des plus difficiles à estimer en pratique), ou la dimension dite de "box-counting". La méthode du "box-counting" est très utilisée en pratique du fait de sa grande simplicité de calcul. Celle-ci consiste à compter le nombre  $N$  d'éléments ou "boîtes" (pixels dans le cas de



champs 2D) de taille  $l$  couvrant l'objet. La mesure de  $N$  dépend de l'échelle  $l$  et de la dimension fractale  $D_f$  selon :

$$N(l) \approx l^{-D_f}$$

2.3


où  $\approx$  indique une égalité valable à des facteurs multiplicatifs près, dans tous les cas faiblement dépendants de  $l$ . Ainsi,  $D_f$  peut être estimée d'après la pente de  $N(l)$  sur une représentation log-log, telle que :

$$D_f \approx \frac{\ln(N)}{-\ln(l)}$$

2.4

### 2.2.1.3 Invariance d'échelle statistique

L'invariance d'échelle, dans son sens statistique, a été théoriquement proposée par [Kolmogorov \(1940\)](#) avec l'introduction du mouvement Brownien fractionnaire (mBf). Ce modèle stochastique permet de générer des séries aléatoires Gaussiennes dont les trajectoires présentent des propriétés fractales en termes de distribution statistique, ayant pour conséquence notamment leur continuité et leur non dérivabilité (fig.2.15). Le paramètre unique  $H$  du modèle est un paramètre de lissage affectant les propriétés fractales du processus généré. Il est ainsi analogue à une sorte de "dimension fractale" des trajectoires du processus (voir section 2.2.3 pour plus de détails sur ce paramètre). Le modèle mBf illustre l'intérêt physique des processus fractals aléatoires car les mouvements browniens de manière générale sont assez ubiquitaires en physique. [Mandelbrot and Van Ness \(1968\)](#) l'ont rendu célèbre en l'introduisant dans des modèles géophysiques. En particulier, les premiers modèles fractals stochastiques de la topographie ont été développés à partir de cette théorie ([Mandelbrot, 1975](#)).



**Figure 2.15 : Mouvement Brownien fractionnaire unidimensionnel généré avec une intégration fractionnaire d'ordre  $H = 0.6$**

De par leur nature aléatoire, les processus fractals possèdent certaines propriétés statistiques qui permettent de mettre en évidence leur comportement fractal. Par exemple, dans le domaine de Fourier, la densité spectrale de puissance (que nous appellerons également par commodité le spectre de puissance dans la suite) de tout processus ayant des propriétés d'invariance d'échelle suit la loi d'échelle suivante :

$$E(k) = k^{-\beta}$$

2.5

où  $k$  correspond au nombre d'onde (fréquences) qui est directement lié à la résolution du processus, et  $\beta$  est la pente négative de  $E(k)$  en représentation log-log (voir section 2.3.2.1 pour la méthode d'estimation du spectre). L'évolution linéaire de  $\log(E(k))$  est caractéristique d'un comportement fractal au sens statistique. La figure 2.16 montre ce comportement pour des images de volcans acquises par capteur optique (Laferrière and Gaonac'h, 1999). L'estimation de l'exposant spectral  $\beta$  est une manière de caractériser et de différencier le comportement fractal de différentes variables.




Figure 2.16 : Spectres de puissance estimés à partir d'images satellites (SPOT) et aériennes acquises dans le visible (Laferrière and Gaonac'h, 1999).

De même que le spectre, les fluctuations ou incréments d'un processus fractal suivent également une loi d'échelle de la forme :

$$\Delta R \approx \Phi \Delta x^H$$

2.6

avec  $\Phi$  le processus aléatoire normalisé (série temporelle ou champ 2D/3D), et  $\Delta x$  une fenêtre de taille variable (correspondant à l'échelle) pour laquelle les différentes valeurs des

fluctuations  $\Delta R$  sont estimées (voir section 2.3.2.2). Cette équation permet d'estimer le paramètre caractéristique unique  $H$  du processus fractal. La connaissance du paramètre  $H$  permet en effet de retrouver la valeur de l'exposant spectral par une équation simple. Il est intéressant de remarquer que l'équation 2.6 est analogue à la loi de [Kolmogorov \(1941\)](#) décrivant la distribution statistique des incréments de vitesse dans les phénomènes turbulents (Eq.2.1), pour lesquelles l'exposant d'échelle  $H$  vaut  $1/3$  ([Schmitt et al., 1993](#)).

Suite aux travaux de Kolmogorov, d'autres modèles de processus stochastiques fractals ont été développés. Le mouvement de Lévy fractionnaire (mLf) est en quelque sorte une généralisation du mBf aux processus aléatoires non gaussiens et à variance non-bornée. En effet, dans leur étude de l'hétérogénéité spatiale des roches sédimentaires, [Painter and Paterson \(1994\)](#) ont montré l'intérêt des mLf pour capturer la forte variabilité présente dans les phénomènes naturels. Comparés aux mBf qui se basent sur des lois gaussiennes pour générer le signal aléatoire, les mLf utilisent des lois de [Lévy \(1937\)](#) permettant la génération de processus à variance non-bornée. Les processus de Lévy ont été appliqués dans divers domaines de la géophysique tels que la turbulence ([Schertzer and Lovejoy, 1987](#)) ou la topographie ([Mandelbrot and Van Ness, 1968](#)). Parmi les premiers modèles fractals stochastiques, nous pouvons également citer le modèle  $\beta$  introduit dans la littérature de la turbulence par [Frisch et al. \(1978\)](#). Ce modèle a été développé sur le principe des cascades multiplicatives. Celles-ci sont des procédures itératives qui permettent de construire des processus ou champs aléatoires fractals aux propriétés statistiques "complexes", les rendant adaptées à l'étude des phénomènes intermittents souvent présents en géophysique (voir section 2.2.3).

#### 2.2.1.4 Processus multifractals

Les modèles stochastiques présentés jusqu'ici permettent de représenter le comportement "monofractal" des processus. Dans ce cas, la dimension fractale ou le paramètre d'échelle les caractérisant est considéré comme étant unique, limitant la modélisation multi-échelle à certains types de variabilité. Cependant, la plupart des processus géophysiques sont caractérisés par des statistiques plus complexes. En hydrologie opérationnelle, les événements rares et extrêmes présents dans les précipitations ou l'humidité du sol correspondent à des ordres de statistique élevés et nécessitent d'être détectés ([Hubert et al., 1993](#)). C'est pourquoi, des modèles multifractals, caractérisés par un spectre infini de dimensions fractales, ont été proposés pour rendre compte d'un ensemble plus exhaustif de propriétés statistiques.

A partir des travaux de [Parisi and Frisch \(1985\)](#), [Schertzer and Lovejoy \(1987\)](#) ont initialement établi le formalisme des multifractales à travers l'équation fondamentale :

$$Pr(\Phi_\lambda > \lambda^\gamma) \approx \lambda^{-c(\gamma)} \quad 2.7$$

Ci-dessus  $\Phi_\lambda$  est un processus stochastique (ou champ aléatoire dans un cas multidimensionnel), normalisé et défini (ou observé) à une résolution  $\lambda$ . La normalisation de la moyenne est imposée par souci de réalisme physique, sous-entendant ainsi une conservation statistique de l'espérance du processus quand la résolution d'observation du processus change (conservation canonique ; [Mandelbrot, 1974](#)). L'équation 2.7 exprime le fait que, pour un processus multifractal, la probabilité de dépasser un seuil varie en loi puissance avec la résolution à laquelle le processus est défini (ou observé). L'exposant  $c(\gamma)$  est appelé "codimension fractale" du processus et dépend de l'amplitude des seuils retenus. Ces derniers sont définis par la loi puissance suivante :

$$T = \lambda^\gamma \quad 2.8$$

avec  $\gamma$  la notion de singularité, caractérisant l'amplitude du processus indépendamment de la résolution. Cette notion permet de prendre en compte le fait que les variations d'un processus tendent à être lissées quand on l'agrège à des résolutions plus grossières, et donc de définir un seuil qui garde la même signification physique lorsque l'on change la résolution. Ainsi, d'après l'équation 2.7, à chaque singularité est associée une codimension  $c(\gamma)$ , correspondant à une famille de seuils d'amplitudes variées. En pratique, si l'on seuille un champ multifractal à divers niveaux d'amplitude ( $T_i$ ), on obtient plusieurs ensembles géométriques de dimensions fractales différentes (cf. figure 2.17 pour une illustration avec deux seuils différents). D'un point de vue plus physique, les singularités élevées (détectées par des seuils élevés) sont associées aux événements rares et extrêmes, caractérisés par de fortes codimensions et inversement par de faibles dimensions fractales. C'est notamment le cas du seuillage représenté en rouge sur la figure 2.17. On peut remarquer que le formalisme des codimensions fractales est directement relié aux notions de box-counting présentées précédemment. En effet, les codimensions fractales sont reliées aux dimensions fractales des ensembles géométriques obtenus par seuillage par la relation  $c(\gamma) = D - D_f(\gamma)$ , où  $D = 2$  dans un cas bidimensionnel.




Figure 2.17 : Champ multifractal bidimensionnel généré à partir du modèle des Multifractales Universelles (Schertzer and Lovejoy, 1987), auquel deux niveaux de seuillage  $T_1$  et  $T_2$  ont été appliqués tels que  $T_1 < T_2$

Ainsi,  $c(\gamma)$  peut être décrite comme une "fonction de codimension", croissante avec  $\gamma$ , caractérisant entièrement les propriétés statistiques multi-échelles du champ  $\Phi_\lambda$ . Pour un champ multifractal,  $c(\gamma)$  se présente généralement sous la forme d'une courbe convexe et positive (fig.2.18) (Schertzer and Lovejoy, 2002). Lorsque la moyenne du champ est conservée statistiquement (conservation canonique), la fonction de codimension se situe entièrement au-dessus de la première bissectrice. Dans ce cas,  $c(\gamma)$  est caractérisée par un point fixe  $C_1$  correspondant à la codimension du champ moyen, et situé à l'intersection avec la bissectrice. On peut noter que ce formalisme est une généralisation des cas monofractals vue précédemment. En particulier, le cas du modèle  $\beta$  introduit par Frisch et al. (1978) peut être modélisé par un formalisme similaire, mais avec une fonction de codimension qui correspondrait au cas trivial  $c(\gamma) = \text{const.}$ .




Figure 2.18 : Allure d'une fonction de codimension dans le cas de champs multifractal ( $c(\gamma)$  convexe) et monofractal ( $c(\gamma) = \text{const.}$ ) (d'après fig.2.17).

Puisque les distributions de probabilité et les moments statistiques d'une variable aléatoire positive sont liés par une transformée de Mellin, [Schertzer and Lovejoy \(1987\)](#) ont proposé une relation équivalente à (2.6) :

$$\langle \Phi_{\lambda}^q \rangle \approx \lambda^{K(q)}$$

**2.9**

où  $\langle \cdot \rangle$  correspond à l'opérateur de la moyenne statistique (c'est-à-dire l'espérance d'une variable aléatoire),  $q$  est l'ordre de moment ( $q \geq 0$ ), et  $K(q)$  est appelée la "fonction d'échelle des moments". Ainsi, l'équation 2.9 montre que, pour tout ordre de moment, les moments statistiques et la résolution sont liés à travers une loi puissance. L'équivalence entre les équations 2.7 et 2.9 met en évidence la relation directe entre singularités et ordres de moments, ainsi qu'entre les fonctions  $K(q)$  et  $c(\gamma)$  toutes les deux reliées par une transformée de Legendre. Tout comme  $c(\gamma)$ ,  $K(q)$  est une fonction convexe (avec un point fixe à  $K(1) = 0$  dû à la conservation de la moyenne  $\langle \Phi \rangle$  qui est supposée indépendante de l'échelle), qui caractérise entièrement le champ multifractal.

## 2.2.2 Les cascades multiplicatives

### 2.2.2.1 Principe de construction

Les cascades multiplicatives sont des modèles stochastiques qui peuvent être utilisés pour construire des processus multifractals respectant ainsi les propriétés d'échelle statistiques énoncées précédemment (Eq.2.7-9). Les cascades sont dites "multiplicatives" car elles sont définies selon une construction itérative multiplicative (fig.2.19): si l'on considère un processus aléatoire à deux dimensions (champ), chaque pixel à la résolution  $\lambda_{n+1}$  (avec  $n$  le niveau de construction de la cascade) est le produit du pixel à la résolution plus grossière ( $\lambda_n$ ) multiplié par une variable aléatoire  $\mu\varepsilon$  appelée incrément multiplicatif. Cela est décrit par l'équation suivante :

$$\Phi_{\lambda_{n+1}} \stackrel{d}{=} \mu\varepsilon \times \Phi_{\lambda_n}$$

**2.10**

où  $\stackrel{d}{=}$  signifie que l'égalité est valable en distribution, c'est-à-dire que les termes de droite et de gauche de l'égalité ont la même distribution de probabilité. De cette manière, les propriétés statistiques du champ  $\Phi_{\lambda_{n+1}}$  sont directement reliées aux propriétés statistiques du champ plus "grossier"  $\Phi_{\lambda_n}$ . Si les incréments multiplicatifs utilisés à chaque étape de la construction itérative sont indépendants et identiquement distribués, et distribués indépendamment de la résolution, alors le champ final présentera des propriétés d'invariance d'échelle (autosimilarité statistique). De plus, cette procédure assure également une



conservation de la moyenne lorsque la résolution du champ augmente. Cela est vérifié en imposant que la moyenne statistique des incréments soit égale à 1 :  $\langle \mu \varepsilon \rangle = 1$ .





Figure 2.19: Schéma de principe d'une cascade multiplicative (d'après Verrier, 2011).

#### 2.2.2.2 Exemples de modèles


Nous décrivons ici quelques exemples connus de cascades multiplicatives, qui respectent la structure décrite en figure 2.19, mais qui diffèrent les uns des autres par le choix des variables aléatoires  $\mu \varepsilon$  principalement. Un récapitulatif de ces modèles de cascades est présenté dans le tableau 2.3. Les premiers modèles ont été construits dans le cadre de la turbulence tels que le modèle  $\beta$  (Frisch et al., 1978) et le modèle  $\alpha$  (Schertzer and Lovejoy, 1984) qui correspondent à une construction discrète de cascades. Ces modèles de cascades "discrètes" se caractérisent par des incréments multiplicatifs  $\mu \varepsilon$  (Eq.2.10) qui se limitent à deux valeurs possibles. Dans le cas du modèle  $\beta$ , ces incréments peuvent avoir une valeur nulle ou strictement supérieure à 1, générant ainsi un champ monofractal dont les pixels ont des valeurs nulles ou positives. Le modèle  $\alpha$  utilise quant à lui des incréments pouvant avoir

une valeur inférieure à 1 ou supérieure à 1, générant respectivement des valeurs de pixels décroissantes ou croissantes lorsque la résolution augmente. De cette manière, les multiplications successives intervenant aux différentes étapes de la cascade permettent de générer un champ multifractal constitué de toute une hiérarchie de singularités et ainsi de dimensions fractales. Parmi les modèles historiques de cascades, nous pouvons également citer le modèle Log-Normal (Kolmogorov, 1962; Oboukhov, 1962). Celui-ci concerne des cascades dont les incréments multiplicatifs sont définis par une loi de distribution de type log-normal. Bien qu'il n'ait pas été explicitement construit selon la dichotomie "continu/discret" au sens du formalisme proposé ultérieurement, ce modèle reste implicitement le premier modèle de cascades "continues" en échelle, correspondant notamment à un cas particulier du modèle des Multifractales Universelles défini ci-après (Seuront et al., 1996).

Ainsi, des modèles plus élaborés ont été proposés, généralisant le cas discret à des cascades continues (Dubrulle, 1994; Schertzer and Lovejoy, 1987, 1991, 1997; She and Levêque, 1994). Ces derniers sont basés sur un nombre infini d'étapes entre chaque paire de résolutions, menant ainsi à la continuité en échelle (fig.2.20). L'avantage des cascades continues est double. Premièrement, elles peuvent représenter des structures éventuellement plus réalistes, en évitant toute discrétisation arbitraire d'échelle (fig.2.21). De plus, elles convergent souvent vers des variables aléatoires dont la loi de distribution est "log-infiniment divisible" (Schertzer et al., 2002), générant ainsi des processus caractérisés par un faible nombre de degrés de liberté. Ceci est intéressant puisque que les champs multifractals construits par des processus de cascades multiplicatives auraient sinon besoin d'un nombre infini de paramètres d'échelle (un pour chaque dimension fractale). En effet, dans le cas général  $K(q)$  pourrait être n'importe quelle fonction convexe vérifiant la contrainte  $K(1) = 0$ .



*Figure 2.20 : Passage des cascades à échelles discrètes aux cascades à échelles continues (d'après Schertzer and Lovejoy, 1997).*



*Figure 2.21 : Exemples de champs multifractals construits par cascades multiplicatives : (a) cas d'une simulation à échelle discrète via le modèle  $\alpha$ , (b) cas continu via le modèle des Multifractales Universelles. L'échelle de couleur est en niveau de gris, avec les faibles valeurs en bleu pour améliorer le contraste (d'après [Lovejoy and Schertzer, 2010b](#)).*

Ainsi, des modèles de cascades continues en échelle, également appelés "modèles universels", ont été développés, ne nécessitant qu'un faible nombre de paramètres (deux en l'occurrence). Par exemple, [She and Levêque\(1994\)](#) ont proposé le modèle Log-Poisson qui construit des champs multifractals à partir de la génération d'une variable aléatoire  $\mu\varepsilon$  dont la loi de distribution est de type log-Poisson. Les lois (log-) Poisson font partie des lois (log-) infiniment-divisibles, tout comme en font partie les lois (log-) stables (incluant le cas gaussien). Le modèle des Multifractales Universelles (MU) proposé par [Schertzer and Lovejoy \(1987\)](#) utilise des variables aléatoires  $\mu\varepsilon$  de lois log-stables pour générer le processus multifractal. Ces deux modèles de cascades continues ont été appliqués dans divers domaines de la géophysique : pour l'étude de la pluie ([Deidda, 2000](#)) et de l'humidité du sol ([Mascaro et al., 2010](#)) dans le cas du modèle Log-Poisson ; et en topographie ([Lavallée et al., 1993](#)), précipitations et nuages ([Tessier et al., 1993](#)), et plus récemment en analyse d'indices optiques d'humidité du sol et de végétation ([Lovejoy et al., 2008b](#)) pour ce qui est du modèle MU.

TYPE	MODELE	DESCRIPTION	APPLICATIONS
DISCRET	Modèle $\beta$	Monofractal $\mu\varepsilon = 0$ ou $\mu\varepsilon > 1$	Turbulence (Frisch et al., 1978)
	Modèle $\alpha$	Multifractal $\mu\varepsilon < 1$ ou $\mu\varepsilon > 1$	Turbulence (Schertzer and Lovejoy., 1984)
CONTINU	Modèle Log-Poisson	Multifractal lois log-Poisson	Turbulence (She and Levêque, 1994) Précipitations (Deidda, 2000) Humidité du sol (Mascaro et al., 2010)
	Modèle des Multifractales Universelles	Multifractal lois log-stables	Turbulence (Schertzer and Lovejoy, 1987) Topographie (Lavallée et al., 1993) Pluie et nuages (Tessier et al., 1993) Indices humidité, végétation (Lovejoy et al., 2008)

**Tableau 2.3 : Présentation de quelques modèles connus de cascades multiplicatives utilisés en géophysique pour l'étude et la génération de processus multifractals.**

### 2.2.3 Multifractales Universelles

Les modèles stochastiques correspondant aux cascades log-Poisson ou log-stables ont tous deux eu des applications en géophysique. Cependant, bien que le modèle Log-Poisson ait permis l'étude de différentes variables géophysiques telles que la pluie et l'humidité du sol, celui-ci impose la présence d'un maximum théorique sur les singularités (et l'intensité des extrema) susceptibles d'être observés, le rendant parfois inadapté pour modéliser des processus aux singularités non bornées. D'autre part, le modèle MU provient d'une construction mathématique qui est basée sur une version multiplicative du théorème central limite bien connu en statistique (ce qui justifie l'émergence de lois log-stables ([Schertzer and Lovejoy, 1997](#))). **Le modèle MU a déjà été utilisé pour caractériser une large gamme de processus** et variables géophysiques ou biophysiques : précipitations, nuages, vent, température, topographie, humidité du sol, végétation... **De plus, le formalisme du modèle MU est caractérisé par des paramètres souvent plus faciles à interpréter physiquement et à visualiser**, ce qui, pour des physiciens, le rend potentiellement plus compréhensible et accessible que le modèle Log-Poisson. C'est principalement pour ces différentes raisons que nous avons choisi d'utiliser le modèle MU dans cette étude. Pour plus de détails sur le degré de généralité du modèle MU et ses hypothèses mathématiques sous-jacentes, nous invitons le lecteur à se référer à [Schertzer and Lovejoy\(1997\)](#) et [Gupta and Waymire \(1997\)](#).

La fonction d'échelle  $K(q)$  intervenant dans l'équation 2.9 permet de décrire les propriétés statistiques multi-échelles du champ multifractal. Selon le modèle de cascade utilisé, cette fonction peut être définie de plusieurs manières. Dans le cas du modèle MU, celle-ci est modélisée à partir de deux paramètres "universels" selon l'équation suivante (Schertzer and Lovejoy, 1987) :

$$K(q) = \frac{C_1}{(\alpha - 1)} (q^\alpha - q)$$

2.11

où  $\alpha$  est le degré de multifractalité du champ (c'est aussi le degré de stabilité des variables log-stables utilisées dans la construction du modèle MU). Il varie entre 0 (cas monofractal) et 2 (cas log-normal) et exprime la rapidité avec laquelle la codimension fractale évolue en fonction de la singularité. Le second paramètre  $C_1$  est la codimension associée au champ moyen (moment d'ordre 1) :  $C_1 = K'(1)$ . D'un point de vue plus physique, ce paramètre indique l'hétérogénéité ou dispersion du champ : il varie de 0 pour un champ homogène, à la valeur de la dimension  $D$  de l'espace dans le cas d'un champ fortement intermittent. D'après la transformée de Legendre,  $c(C_1) = K'(1)$  est aussi défini comme le point fixe de la fonction de codimension (cf. section 2.2.1.4). L'effet de ces deux paramètres sur la texture d'images multifractales simulées est présenté en section 2.3.1.

De manière générale, la plupart des processus géophysiques sont définis comme étant "non-conservatifs". Cette appellation vient du formalisme des cascades multiplicatives (Gagnon et al., 2006) et fait référence à tout processus caractérisé par un certain degré d'intégration fractionnaire. D'un point de vue physique, cela désigne le fait que la moyenne statistique du processus multifractal n'est pas strictement conservée en fonction de l'échelle. Or, nous venons de voir précédemment que les modèles de cascades multifractales imposent une condition de conservation de la moyenne. Ainsi, pour prendre en compte une plus large gamme de processus, une extension du modèle MU aux processus non-conservatifs a été proposée. Il s'agit du modèle FIF (Fractionnally Integrated Flux; Schertzer and Lovejoy, 1991) faisant intervenir un troisième paramètre multi-échelle, le degré d'intégration fractionnaire  $H$ . Ce paramètre décrit à quel point le processus est non-conservatif : plus concrètement, une forte valeur de  $H$  correspondra à un processus présentant une texture davantage "lissée" (voir section 2.3.1). Le processus "intégré" est alors noté  $R_\lambda$  et est caractérisé par une évolution en loi puissance de ses incréments stationnaires, comme décrit dans l'équation 2.6 que nous rappelons ici :

$$\Delta R_\lambda \approx \Phi_\lambda \Delta x^H$$

où  $\Delta R_\lambda$  sont les incréments (ou fluctuations) du processus estimés sur une fenêtre variable  $\Delta x$ , équivalente à l'échelle  $l$ . Nous pouvons remarquer que dans le cas  $H = 0$ , cette équation correspond au cas conservatif  $\Phi_\lambda$ . De plus, pour les processus à deux dimensions, l'équation

2.6 s'applique également aux autres directions de l'espace (incréments selon  $\Delta y$  par exemple), avec le même exposant  $H$  dans le cas de processus isotropes.

Par souci de simplicité, les deux versions MU et FIF du modèle de [Schertzer and Lovejoy \(1987, 1991\)](#) étant fortement similaires, nous allons par la suite les regrouper sous le même nom de "modèle MU". Ainsi, lorsque nous ferons référence au modèle MU, nous entendrons la version FIF faisant intervenir les trois paramètres universels  $\alpha$ ,  $C_1$  et  $H$ .

Dans cette partie, nous venons de présenter le formalisme théorique des fractales, en définissant les notions d'invariance d'échelle géométrique puis statistique. Nous avons vu que les premiers modèles multi-échelles monofractals développés dans le domaine de la turbulence se restreignaient à une gamme limitée de variabilité. C'est pourquoi des modèles plus complexes ont été proposés, basés sur des lois de distribution non gaussiennes, les rendant applicables à une plus grande gamme de processus géophysiques. Construits sur des procédures de cascades multiplicatives, ces modèles multifractals ont montré leur potentiel pour modéliser la variabilité de phénomènes très intermittents. **En particulier, le modèle des Multifractales Universelles permet de caractériser l'ensemble des propriétés multifractales de processus aléatoires grâce à seulement deux paramètres (ou trois dans le cas du modèle FIF), dont l'interprétation est simple en termes de représentation physique.**

## 2.3 Simulation et analyse de Multifractales Universelles

Cette partie présente l'ensemble des techniques et outils statistiques que j'ai utilisés dans cette thèse pour étudier les propriétés multi-échelles des processus de surface. Tout d'abord, une première sous-partie sera dédiée à la description d'un simulateur de champs multifractals universels. Celui-ci nous permettra d'une part de mieux comprendre les étapes de construction du modèle MU ainsi que le rôle de chaque paramètre, mais également de bénéficier d'un outil permettant de reconstruire les propriétés multi-échelles des processus étudiés. Ensuite, nous décrirons les différents estimateurs statistiques multi-échelles que j'ai appliqués aux images pour en extraire leurs propriétés fractales. En particulier, ces outils nous permettront d'avoir accès aux gammes d'échelles pour lesquelles il y a invariance d'échelle ainsi qu'aux paramètres universels. Puis, une dernière sous-partie présentera l'algorithme général que j'ai développé durant cette thèse permettant d'étudier le comportement multi-échelle de séries temporelles d'images satellites. De manière générale, comme ces travaux se basent sur l'étude de processus 2D, nous nous focaliserons sur la présentation des versions bidimensionnelles des techniques et méthodes décrites ci-après.



## 2.3.1 Simulateur de champs multifractals


### 2.3.1.1 Principe général

Le simulateur que nous présentons ici sert à générer des champs aléatoires multifractals connaissant les trois paramètres  $\alpha$ ,  $C_1$  et  $H$  du modèle MU (version FIF) ainsi que la taille du domaine de simulation correspondant à la résolution maximale. Ce simulateur comprend plusieurs étapes, lesquelles sont décrites de manière détaillée dans divers travaux sur les processus multifractals tels que [Lovejoy and Schertzer \(2010b, 2010c\)](#), [Pecknold et al. \(1993\)](#), et [Verrier \(2011\)](#). Nous invitons donc le lecteur à se référer à ces travaux pour plus d'informations sur ces étapes de traitement.

De manière générale, ce simulateur vise à reproduire la construction mathématique des cascades multiplicatives correspondant au modèle MU/FIF, définies en section 2.2.2. Cette construction repose sur cinq grandes étapes (figure 2.28) que nous décrivons ci-dessous :

#### 1) Génération de la variable aléatoire log-stable $\gamma_\alpha$ :

La construction du modèle MU se base sur la génération d'une variable aléatoire log-stable, correspondant ici à un bruit blanc  $\alpha$ -stable  $\gamma_\alpha$  (fig.2.22). Le paramètre  $\alpha$  désigne le degré de multifractalité du modèle MU, et correspond également à l'indice de stabilité relatif aux lois stables ([Schertzer et al., 2002](#)). Ainsi, une première étape consiste à générer  $\gamma_\alpha$  grâce à l'algorithme de [Chambers et al. \(1976\)](#). Cet algorithme permet de simuler des variables stables de manière rapide et efficace, simplement à partir de réalisations de variables aléatoires indépendantes et suivant des lois uniformes et exponentielles.




**Figure 2.22 : Exemple de réalisation bidimensionnelle de la variable aléatoire  $\gamma_\alpha$  obtenue à partir de la méthode de [Chambers et al. \(1976\)](#). Ici nous avons défini  $\alpha = 2$  et  $\lambda = 512$ .**

2) *Multiplication par le facteur d'amplitude  $\sigma$  :*

La variable aléatoire  $\gamma_\alpha$  est ensuite multipliée par un facteur d'amplitude  $\sigma$  (fig.2.23) permettant d'intégrer le paramètre  $C_1$  dans la construction de la cascade :

$$\sigma = \left( \frac{C_1}{|\alpha - 1|} \right)^{\frac{1}{\alpha}}$$

2.12



*Figure 2.23 : Résultat de la multiplication de  $\gamma_\alpha$  par le facteur d'amplitude  $\sigma$  tel que  $C_1 = 0.05$ .*


3) *Création du générateur  $\Gamma_\lambda$  :*

Afin d'obtenir le champ multifractal, il faut au préalable construire la variable aléatoire  $\Gamma_\lambda$  appelée "générateur" (fig.2.24). Celle-ci est obtenue par convolution de la variable log-stable  $\sigma \cdot \gamma_\alpha$  et un filtre  $g_\alpha$  (en loi puissance négative de la distance) tel que :

$$g_\alpha(\vec{x}) = \frac{1}{\|\vec{x}\|^{\frac{D}{\alpha}}}$$

2.13

où  $\|\cdot\|$  désigne la norme Euclidienne, soit dans le cas 2D  $\|\vec{x}\| = \|(x, y)\| = \sqrt{x^2 + y^2}$ . Par souci de rapidité, les opérations de convolution présentes dans ce simulateur sont réalisées numériquement dans le domaine de Fourier au moyen de la *fft* ou "Fast Fourier Transform" à deux dimensions.  $D$  est ici pris égal à 2 pour une simulation bidimensionnelle.




*Figure 2.24 : Générateur obtenu après convolution de  $\sigma \cdot \gamma_\alpha$  et du filtre  $g_\alpha$ .*

4) *Génération du champ conservatif  $\Phi_\lambda$  :*

Le champ conservatif est finalement obtenu par exponentiation du générateur, puis normalisation (fig.2.25) :

$$\Phi_\lambda = \frac{e^{\Gamma_\lambda}}{\langle e^{\Gamma_\lambda} \rangle}$$

**2.14**



*Figure 2.25 : Champ multifractal conservatif.*


5) *Génération du champ intégré  $R_\lambda$*  :

Dans le cas de la simulation d'un champ non-conservatif (fig.2.26), une dernière étape consiste à appliquer une convolution à  $\Phi_\lambda$  par le filtre en loi puissance décroissante  $g_H$ , défini par :


$$g_H(\vec{x}) = \frac{1}{\|\vec{x}\|^{D-H}}$$

2.15

Cette convolution revient à réaliser une intégration fractionnaire d'ordre  $H$  (inférieur à  $D$ ) (Gagnon et al., 2006). Dans le cas particulier où  $H = 0$ , on omet l'étape 5 puisque ici le champ aléatoire à générer est conservatif, soit  $R_\lambda = \Phi_\lambda$ .



*Figure 2.26 : Champ multifractal intégré (non-conservatif) obtenu par convolution de  $\Phi_\lambda$  et du filtre  $g_H$ . Ici le degré d'intégration fractionnaire a été défini tel que  $H = 0.3$ .*



*Figure 2.27 : Schéma de principe d'un simulateur de champs multifractals (d'après Verrier, 2011).*

### 2.3.1.2 Exemples de simulations multifractales

En appliquant la procédure de simulation décrite ci-dessus, nous avons généré plusieurs champs multifractals à partir de différentes valeurs de paramètres universels, et ce afin d'observer l'effet de ces paramètres sur la texture des images simulées. Pour cela, nous avons tout d'abord généré un champ multifractal non-conservatif  $R_{simu}$  tel que  $\alpha = 2$ ,  $C_1 = 0.05$ ,  $H = 0.3$  et  $\lambda = 512$  (image de 512 x 512 pixels). Ces valeurs de paramètres ont été choisies car elles sont assez communes en géophysique (Gagnon et al., 2006; Lovejoy and Schertzer, 2010c; Lovejoy and Schertzer, 2006; Schmitt et al., 1993). Ensuite, nous avons généré trois autres champs multifractals en utilisant les mêmes réalisations aléatoires prises en entrée de l'algorithme de Chambers et al. (1976) (fig.2.28), mais en répétant les cinq étapes ci-dessus tout en changeant à chaque fois la valeur d'un des trois paramètres universels. La figure 2.29 compare le champ de référence  $R_{simu}$  aux trois autres champs obtenus :  $R_{simu_\alpha}$  ayant comme paramètre modifié  $\alpha = 1$ ,  $R_{simu_{C_1}}$  tel que  $C_1 = 0.5$  et  $R_{simu_H}$  tel que  $H = 1$ . Ces quatre champs ont été normalisés de sorte que leur moyenne soit unitaire et que leur écart-type soit égal à 2.

Le degré d'intégration fractionnaire  $H$  est peut-être le paramètre pour lequel il est le plus évident d'observer ses effets sur la texture du champ. En effet, nous rappelons que celui-ci est caractéristique des champs non-conservatifs, c'est-à-dire les champs multifractals pour lesquels la moyenne n'est pas conservée en fonction de l'échelle. Ainsi, lorsque la valeur de  $H$  augmente, le degré d'intégration est plus élevé, ayant pour conséquence d'augmenter le niveau de "lissage" du signal présent dans l'image. Comme nous pouvons le voir sur la figure 2.29, le champ  $R_{simu_H}$  ( $H = 1$ ) présente des variations plus lentes et progressives de ses valeurs que le champ  $R_{simu}$  ( $H = 0.3$ ).

Le paramètre  $C_1$  définit la codimension fractale associée au champ moyen. Ainsi, plus celui-ci est élevé, plus grande sera la dispersion des structures d'intensité moyenne dans l'image. Dans le cas où  $C_1$  est faible,  $R_{simu}$  présente une répartition homogène de ses valeurs dans l'image, remplissant ainsi l'espace dans lequel il est défini. A l'inverse, lorsque  $C_1$  est plus élevé,  $R_{simu_{C_1}}$  présente une répartition plus dispersée avec des pics très intenses (jusqu'à plus de 100 fois la valeur moyenne), espacés entre eux. Dans ce cas, le champ présente des événements extrêmes très localisés, se rapprochant ainsi d'un champ fortement intermittent. Les valeurs du paramètre  $C_1$  peuvent varier entre 0 et la dimension  $D$  de l'espace.

Le degré de multifractalité  $\alpha$  détermine la rapidité avec laquelle l'hétérogénéité du champ (dispersion) change lorsqu'on s'éloigne du champ moyen. En d'autres termes, il définit l'évolution de la courbe  $c(\gamma)$  (fig.2.18). Lorsque  $\alpha = 0$ , celle-ci est constante pour toutes les singularités  $\gamma$ , correspondant ainsi à une cascade monofractale. Lorsque la valeur  $\alpha$  augmente,  $c(\gamma)$  devient de plus en plus convexe, jusqu'à atteindre le cas extrême où  $\alpha = 2$



correspondant à une cascade ayant le plus haut niveau de multifractalité (cascade log-normale). Visuellement, les effets du paramètre  $\alpha$  sur la texture de l'image sont plus difficiles à définir que ceux des autres paramètres du modèle. Cependant, une manière d'observer son impact est de détecter l'apparition de zones assez homogènes et d'intensité faible, en bleu foncé sur la figure, lorsque la valeur de  $\alpha$  diminue. Cela peut se voir notamment sur  $R_{simu_\alpha}$  qui présente de grandes zones d'intensité faibles, par comparaison à  $R_{simu}$  pour lequel les intensités faibles occupent continûment des domaines plus restreints.




Figure 2.28 : Champs multifractals universels simulés à partir du modèle MU.


Le simulateur présenté ci-dessus sera réutilisé dans la suite de ce manuscrit pour générer certains champs multifractals. **Ces derniers nous serviront d'une part à démontrer l'intérêt des estimateurs statistiques multi-échelles (section suivante) et d'autre part à modéliser le comportement multi-échelle de certaines variables physiques et biophysiques étudiées au cours de cette thèse (section 4.4).** Il est important de noter que ce simulateur permet la génération de champs multifractals isotropes, c'est-à-dire pour lesquels la loi



d'échelle est la même dans toutes les directions de l'espace. Des versions anisotropes ont également été développées dans la littérature, dont le modèle "auto-affine" (Pecknold et al., 1993; Biaou, 2004; Macor, 2007). Ce dernier est un cas très simple de simulateur anisotrope qui se base sur les mêmes variables aléatoires génératrices utilisées dans le cas isotrope, mais pour lequel les noyaux de convolution sont modifiés afin de permettre une stratification différentielle du champ suivant les deux axes X (vertical) et Y (horizontal) de l'image. Nous présentons en Annexe A deux exemples de champs multifractals anisotropes obtenus par le modèle auto-affine.

### 2.3.2 Description des estimateurs statistiques

**L'analyse multifractale consiste à appliquer plusieurs estimateurs statistiques permettant chacun de révéler certaines propriétés multi-échelles, et en particulier d'estimer les trois paramètres du modèle :  $\alpha$ ,  $C_1$  et  $H$ .** Les estimateurs que nous allons décrire ici sont : le spectre de puissance, les fonctions de structure et les moments statistiques. Par souci de compréhension, nous allons appliquer ces estimateurs à un champ multifractal non-conservatif (fig.2.29) que nous avons généré via le simulateur de multifractales universelles. Ainsi, au fur et à mesure des étapes de l'analyse, nous pourrions comparer les paramètres d'échelle que nous avons estimés aux paramètres théoriques utilisés en entrée du modèle de simulation.



*Figure 2.29 : Champ multifractal  $R_{simu}$  simulé par le modèle MU tel que  $\alpha = 2$ ,  $C_1 = 0.05$ ,  $H = 0.3$  (et  $\lambda = 512$ )*

### 2.3.2.1 Spectre de puissance : détection de l'invariance d'échelle

L'analyse spectrale est une méthode souvent utilisée en géophysique pour caractériser de manière simple et rapide les propriétés multi-échelles des processus (Lovejoy et al., 2008b). **Cette méthode a l'avantage d'être fortement sensible aux changements de comportement d'échelle, mettant en évidence les zones de transition que l'on appellera par la suite "ruptures d'échelle", séparant des intervalles (ou gammes) d'échelle caractérisés par des lois d'échelle différentes.** Ainsi, nous utilisons l'analyse spectrale comme premier outil permettant d'identifier les limites des gammes d'échelles dans lesquelles le processus ou le champ aléatoire étudié présente des propriétés d'invariance d'échelle. L'existence de ruptures d'échelle n'est pas nécessairement une limitation en géosciences : en effet leur position peut parfois être reliée à l'échelle caractéristique de certains phénomènes physiques qui impactent la variabilité du processus étudié.

Pour cela, une première étape de cette analyse spectrale consiste à calculer un estimateur de la Densité Spectrale de Puissance (DSP) du champ multifractal  $R_{simu}$ :

$$P(k_x, k_y) = |fft(R_{simu})|^2 \quad 2.16$$

avec  $P$  la DSP définie à la fois sur l'axe vertical et l'axe horizontal (fig.2.30.a), correspondant respectivement aux nombres d'onde  $k_x$  et  $k_y$  (fréquences spatiales). Ici, l'estimation de la DSP est faite au moyen de la *fft* ou "Fast Fourier Transform" à deux dimensions.

Ensuite, une deuxième étape permet d'estimer le spectre de puissance à une dimension  $E(k)$  en appliquant une intégration angulaire de la forme (Lovejoy et al., 2008b; §8) :

$$E(k) = \int_{\|\vec{k}\|=k} P(\vec{k}) d\vec{k} \quad 2.17$$

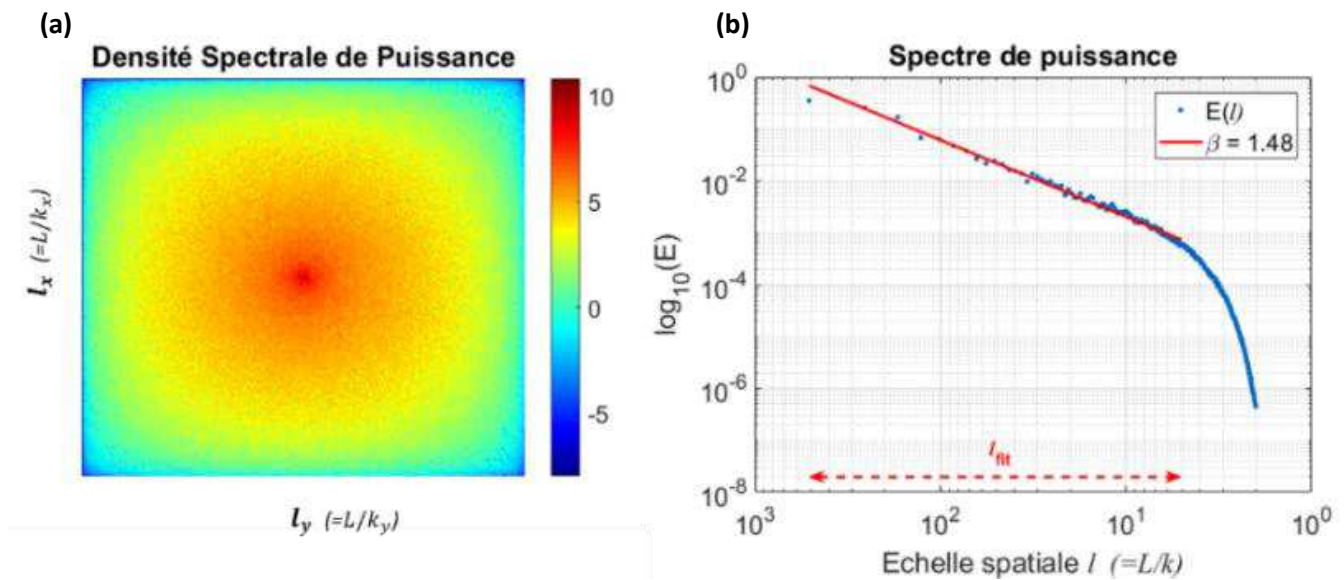
où  $k$  est le module du nombre d'onde et  $\|\cdot\|$  est la norme Euclidienne. En figure 2.30.b, le spectre de puissance du champ multifractal, représenté en coordonnées logarithmiques, présente une évolution linéaire sur la gamme d'échelles  $l_{fit}$  (avec  $l = L/k$ ). Ainsi, d'après l'équation 2.5, le champ présente donc des propriétés d'invariance d'échelle sur la gamme en question. L'exposant spectral  $\beta$ , que nous appellerons aussi parfois "pente spectrale" correspondant à la pente négative de  $\log(E(k))$  en fonction de  $\log(k)$ , est estimé par régression linéaire (droite en rouge) réalisée sur l'intervalle  $l_{fit}$ . Dans le cas de notre champ, nous trouvons une valeur de pente estimée à  $\beta = 1.48$ , avec  $R^2 = 0.99$  et  $\delta = 0.03$  correspondant respectivement au coefficient de détermination et à l'intervalle de confiance à 95% issus des régressions linéaires. Afin de valider cette valeur, nous pouvons nous appuyer

sur le théorème de Wiener-Khintchine qui implique l'existence d'une relation simple entre l'exposant spectral  $\beta$  et les trois autres paramètres multifractals  $\alpha$ ,  $C_1$  et  $H$ :

$$\beta = 1 + 2H - K(2)$$

2.18

Le spectre de puissance est un estimateur statistique du second ordre, ce qui explique le terme  $K(2)$  faisant intervenir les paramètres  $\alpha$  et  $C_1$  pour  $q = 2$  (Eq.2.11). Ainsi, à partir des valeurs théoriques des paramètres universels, les équations 2.18 et 2.11 donnent une valeur théorique  $\beta = 1.5$ . La valeur que nous avons obtenue grâce au spectre est donc très proche de celle attendue. Ceci montre la robustesse du simulateur qui permet d'obtenir la propriété attendue à partir d'une seule réalisation de processus MU. Nous pouvons tout de même remarquer que le simulateur est moins bon aux fréquences les plus élevées, ce qui se traduit par une augmentation "anormale" de la pente spectrale lorsque l'on se rapproche de l'échelle minimale (ici à partir de  $l < 5$ ). Ce phénomène est lié à la discrétisation des noyaux de convolution utilisés. En général, pour une utilisation optimale de ce simulateur il faut générer le champ à une résolution plus élevée que la résolution souhaitée, puis agréger.



**Figure 2.30 :** Représentation log de la Densité Spectrale de Puissance (a) et du Spectre de puissance (b) du champ multifractal  $R_{simu}$ . Pour la DSP, les basses fréquences spatiales (larges échelles) sont situées au centre de l'image. Dans le cas du spectre de puissance, celles-ci sont situées sur la gauche de l'axe des abscisses. La valeur de l'exposant spectral  $\beta$  a été estimée par régression linéaire sur la gamme d'échelles  $l_{fit}$ .

De cette manière, la valeur de  $\beta$  permet d'anticiper sur le caractère non-conservatif du champ, puisque selon l'équation 2.18 les processus intégrés ( $H > 0$ ) sont censés être définis par un exposant spectral plus grand que 1. Cependant, pour estimer le degré d'intégration fractionnaire  $H$  la plupart des techniques utilisées dans la littérature se basent plutôt sur la méthode des fonctions de structure présentée ci-après.

### 2.3.2.2 Fonctions de structure : mise en évidence du caractère non-conservatif


Les fonctions de structures ont été initialement utilisées en turbulence par [Kolmogorov \(1941\)](#) pour mettre en évidence le comportement multi-échelle des incréments de vitesse (Eq.2.1). Elles ont ensuite été largement appliquées en géophysique, en particulier grâce à leur **simplicité de réalisation et d'interprétation**. En effet, à la différence du spectre qui implique une transformée dans le domaine de Fourier, les fonctions de structure représentent simplement dans l'espace réel les fluctuations des observations en fonction de leur distance. De plus, **celles-ci permettent d'avoir directement accès au caractère non-conservatif du champ étudié, à travers l'estimation du paramètre  $H$**  (Eq.2.6).

Plusieurs manières permettent d'estimer ces fluctuations. La plus simple consiste à calculer la moyenne des différences absolues (ou gradient) du champ multifractal non-conservatif  $R_{simu}$ :

$$\Delta R_{diff}(\Delta x) = \langle |R_{simu}(x + \Delta x) - R_{simu}(x)| \rangle$$

2.19

où  $x$  et  $\Delta x$  sont des vecteurs et  $\langle \cdot \rangle$  correspond ici à la moyenne empirique. Notons que la fonction de structure ainsi définie est d'ordre 1. La figure 2.31 présente les fonctions de structure obtenues selon cette équation, et pour chacun des axes X et Y du champ  $R_{simu}$ . L'évolution linéaire de  $\log(\Delta R)$  en fonction de l'échelle  $l$  (correspondant ici à  $\Delta x$  et  $\Delta y$ ) confirme d'une part les propriétés fractales du champ sur la gamme  $l_{fit}$ , et précise d'autre part la valeur du degré d'intégration fractionnaire. En effet, après régression linéaire sur la gamme  $l_{fit}$  nous estimons  $H_x = 0.26$  et  $H_y = 0.27$ , ce qui est proche de la valeur théorique attendue ( $H = 0.3$ ). De plus, les deux valeurs de  $H$  étant très proches dans les deux directions ( $H_x \approx H_y$ ), cela met en évidence le caractère isotrope du champ  $R_{simu}$ . En Annexe B, nous présentons quelques cas d'applications à des champs anisotropes pour lesquels la valeur du paramètre  $H$  a été estimée dans plusieurs directions de l'espace. De manière générale, la méthode des fluctuations par "différence" convient très bien pour les processus caractérisés par un paramètre  $H$  compris entre 0 et 1 ([Lovejoy and Schertzer, 2012a](#)), correspondant ainsi à des fluctuations croissantes avec la distance  $\Delta x$ . Nous utiliserons l'équation 2.19 notamment dans le chapitre 3 pour étudier les propriétés multi-échelles de l'humidité du sol. Rappelons que cette définition des fluctuations est faite au premier ordre ( $q = 1$ ), mais elle peut également prendre en compte les fluctuations du second ordre (soit la variance des incréments), ce qui nous ramène implicitement au cas du variogramme (cf. section 2.1.3).



**Figure 2.31 :** Représentation log des fonctions de structure du champ  $R_{simu}$  estimées par la méthode des "différences", pour les axes X et Y de l'image. Les larges échelles sont situées sur la partie droite de l'axe des abscisses. Notons que les fenêtres de variations  $\Delta x$  et  $\Delta y$  sont ici équivalentes (image carrée).

Cependant, une contrainte avec cette définition est qu'elle ne permet pas de représenter des fluctuations décroissantes avec la distance : pour les champs définis par  $H < 0$ , la fonction de structure converge vers une valeur constante "parasite", ce qui donne une estimation inexacte de  $H$  (qui serait considéré comme égal à 0). Pour pouvoir étendre la gamme de  $H$  auxquelles les fonctions de structure ont accès, une solution est de changer la forme de l'onde estimant les fluctuations. [Lovejoy and Schertzer \(2012b\)](#) ont proposé un formalisme simple de définitions de fluctuations qui est basé sur celui des ondelettes. En particulier, l'ondelette de Haar est une définition qui s'avère être simple de calcul et d'interprétation, tout en permettant d'accéder à des valeurs de  $H$  négatives. Les fluctuations estimées d'après cette méthode se calculent selon l'équation suivante :

$$\Delta R_{haar}(\Delta x) = \left\langle \frac{2}{\Delta x} \left| S(x) + S(x + \Delta x) - 2S\left(x + \frac{\Delta x}{2}\right) \right| \right\rangle$$

**2.20**

avec  $S$  la somme cumulée du champ auquel la moyenne globale a été retranchée. Ainsi, bien que cette définition semble complexe au premier abord, elle consiste simplement à estimer les fluctuations moyennes de  $x$  à  $x + \frac{\Delta x}{2}$  et de  $x + \frac{\Delta x}{2}$  à  $x + \Delta x$ . Nous pouvons noter que, d'un point de vue algorithmique, cette équation implique d'agréger le champ à une résolution deux fois plus petite de manière à permettre le calcul de  $\frac{\Delta x}{2}$ . Cela implique que, dans le cas des ondelettes de Haar, la fonction de structure ne sera pas définie pour l'échelle d'observation

la plus fine. Cette méthode sera utilisée dans le chapitre 4 pour estimer les fonctions de structures des produits de réflectances de surface.

### 2.3.2.3 Moments statistiques : propriétés multifractales

Le spectre de puissance et les fonctions de structure permettent de mettre en évidence les propriétés monofractales des processus. En revanche, **aucune information sur leur nature multifractale n'est donnée via ces estimateurs statistiques. Une solution est de vérifier si les moments statistiques et la fonction d'échelle  $K(q)$  sont effectivement liés par la loi puissance décrite en (2.9)**. Pour cela, plusieurs étapes doivent être suivies :

#### 1) Reconstruction du champ conservatif $\Phi_{\lambda_{max}}$ :

L'équation 2.9 considère les moments du champ conservatif  $\Phi_{\lambda}$ . Pour vérifier si cette équation est valide, une première étape consiste à reconstruire le champ  $\Phi_{\lambda_{max}}$  à partir du champ intégré  $R_{\lambda_{max}}$ , et ce à la résolution d'observation la plus fine  $\lambda_{max}$  à laquelle est associée l'échelle la plus réduite  $l_0$ . Ainsi, une dérivation fractionnaire d'ordre  $H$  doit être appliquée de manière à annuler l'intégration fractionnaire initialement présente dans  $R_{\lambda}$ . Dans ces travaux, la dérivation fractionnaire a été réalisée en estimant le module du gradient. En effet, cet opérateur fournit une approximation numérique à la fois simple et rapide de la dérivation fractionnaire sans connaissance préalable du paramètre  $H$  (Lavallée et al., 1993):

$$\Phi_{\lambda_{max}} = \sqrt{\left(\frac{\partial R_{\lambda_{max}}}{\partial x}\right)^2 + \left(\frac{\partial R_{\lambda_{max}}}{\partial y}\right)^2}$$


2.21

Une fois le champ conservatif retrouvé,  $\Phi_{\lambda_{max}}$  est normalisé par sa moyenne.

#### 2) Dégradation de $\Phi_{\lambda}$ à $\lambda < \lambda_{max}$ :

Cette étape vise à approximer la cascade multiplicative  $\Phi_{\lambda}$  à différentes échelles en effectuant une moyenne itérative du champ à des résolutions plus grossières (fig.2.32). Chaque pixel défini à la résolution  $\lambda_n$  (niveau  $n$  de la cascade) est obtenu par une simple moyenne des pixels voisins à la résolution plus fine  $\lambda_{n+1}$ . Notons que la résolution  $\lambda_n$  de chaque champ monofractal de la cascade est liée au niveau  $n$  selon une puissance de deux tel que  $\lambda_n = 2^n$ . A chaque itération, le champ  $\Phi_{\lambda_n}$  est normalisé de manière à conserver la moyenne du champ global  $\Phi_{\lambda}$  en fonction de la résolution (conservation canonique).





**Figure 2.32 : Dégradation de la résolution d'une cascade multiplicative au moyen d'une succession d'agréations. Ces agrégations reviennent à effectuer une moyenne par intervalles disjoints.**

- 3) *Estimation des moments empiriques (Méthode "Trace-Moments" ; Tessier et al., 1993) :*  
 Pour chaque résolution  $\lambda_n$ , les moments d'ordres  $q$  des différents champs  $\Phi_{\lambda_n}$  de la cascade sont estimés en remplaçant la moyenne statistique (espérance) de l'équation 2.9 par la moyenne empirique. Pour cela, chaque champ  $\Phi_{\lambda_n}$  est élevé à la puissance  $q$ , puis la moyenne empirique est calculée en moyennant toutes les valeurs tel que :

$$M_{\lambda}^q = \frac{1}{\lambda_n^2} \sum_{x=1}^{\lambda_n} \sum_{y=1}^{\lambda_n} \Phi_{\lambda_n}(x, y)^q$$

**2.22**

D'après Hubert et al. (2007), une divergence des moments peut être observée pour des ordres supérieurs à l'ordre de divergence  $q_D \approx 3$ . Ainsi, les moments empiriques ont été estimés pour des ordres  $q$  compris entre 0 et 3 par pas de 0.1.

Les différents moments sont tracés en représentation log-log en fonction de la résolution (fig.2.33). Si une évolution linéaire est observée pour chaque courbe de moments  $\log(M_{\lambda}^q)$ , au moins sur une plage de résolutions significative, alors l'équation 2.9 est vérifiée, ce qui prouve la présence de propriétés multifractales dans le champ étudié.

- 4) *Estimation de la fonction d'échelle et des paramètres universels :*

Afin de caractériser entièrement le champ multifractal, une dernière étape consiste à estimer la fonction d'échelle  $K(q)$  ainsi que les paramètres  $\alpha$  et  $C_1$  du modèle MU. Dans un premier temps, la fonction d'échelle empirique est obtenue à partir des régressions linéaires de chaque courbe de moments (fig.2.33) :

$$K_{emp}(q) = \frac{d \log(M_{\lambda}^q)}{d \log(\lambda)}$$

**2.23**

Puis, les paramètres universels sont estimés par optimisation, en appliquant une méthode de minimisation (fonction "fminsearch" de Matlab) entre  $K_{emp}(q)$  et la forme du modèle MU décrite par l'équation 2.11. Cela revient à estimer les valeurs de  $\alpha$  et  $C_1$  qui minimisent l'équation suivante :

$$\sum_{q=1}^{q_D} \left| K_{emp}(q) - \frac{C_1}{(\alpha - 1)} (q^\alpha - q) \right|^2$$

2.24

Dans le cas du champ  $R_{simu}$ , nous obtenons les valeurs  $\alpha = 1.97$  et  $C_1 = 0.053$ , qui sont proches des valeurs théoriques attendues.

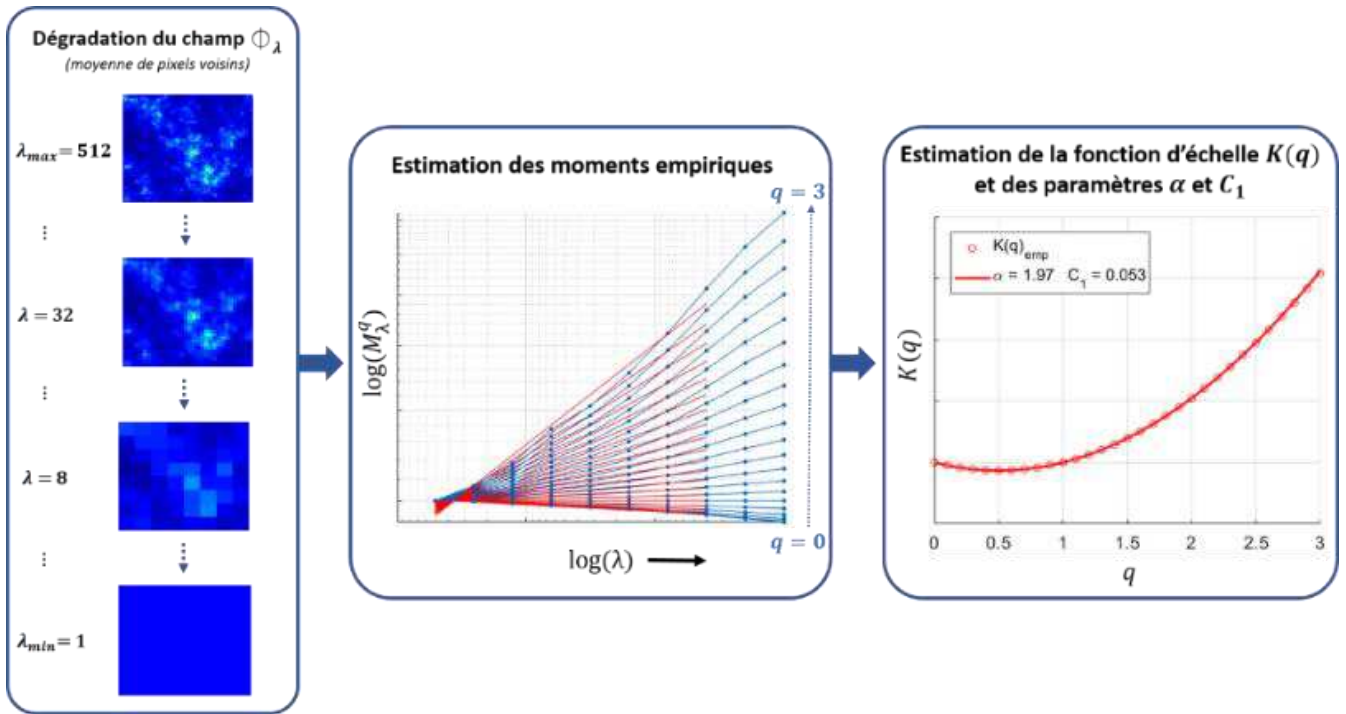


Figure 2.33 : Schéma de principe d'estimation des moments empiriques, de la fonction d'échelle  $K(q)$  ainsi que des paramètres  $\alpha$  et  $C_1$  du modèle MU.

### 2.3.3 Méthodologie générale d'analyse multi-échelle

Au cours de cette thèse, j'ai été amené à traiter un certain nombre d'images satellites, correspondant à des produits de natures différentes (humidité du sol, végétation, température, etc.) et acquises sur des périodes allant de six mois à un an. **Ainsi, d'un point de vue méthodologique, mon travail a principalement consisté à développer en langage Matlab un algorithme général d'analyse multi-échelle. Cet algorithme a été construit de manière à étudier les propriétés multifractales de séries temporelles d'images.** Il fait appel à plusieurs fonctions qui ont été préalablement implémentées par [Verrier \(2011\)](#), permettant entre autres de calculer les estimateurs statistiques décrits précédemment. Les différentes fonctions utilisées dans cet algorithme global sont applicables à tout type d'image (sous condition de quelques prétraitements). C'est pourquoi, la méthodologie d'analyse des différents produits étudiés dans cette thèse se base sur ce même algorithme, lequel est constitué de quatre grandes étapes (fig.2.34) :

#### 1) *Prétraitements des données :*

Avant de réaliser l'analyse multifractale, les produits doivent être préalablement prétraités. Cela consiste tout d'abord à prendre en compte les données manquantes, lesquelles peuvent être dues à des erreurs d'acquisition, de transmission ou à la présence de nuages. Ainsi, une interpolation bilinéaire est appliquée à chaque image pour compléter les données manquantes (notées NaN). Pour minimiser l'impact de l'interpolation sur l'analyse multifractale, les images ayant un pourcentage trop élevé de NaN sont rejetées (voir les chapitres suivants pour plus d'informations sur les niveaux de seuil appliqués).

Ensuite, chaque image doit être tronquée de manière à être composée de  $2^n \times 2^n$  pixels. Cette étape est nécessaire pour permettre l'agrégation des pixels voisins dans l'étape d'estimation des moments empiriques à différentes résolutions spatiales. De plus, lors de l'analyse spectrale, cette condition permet de réduire le temps de calcul de la *fft*, ce qui n'est pas négligeable dans notre cas où l'on traite un nombre conséquent d'images.

#### 2) *Calcul des estimateurs statistiques :*

Les spectres de puissance, fonctions de structures et moments statistiques sont estimés pour chaque image selon la méthode décrite en section 2.3.2. Ainsi, si l'on considère un type de produit (humidité du sol par exemple) constitué d'une série temporelle de  $N$  images, nous obtiendrons alors  $3 \times N$  estimateurs.

#### 3) *Détermination des gammes d'échelles :*

Les gammes d'échelles pour lesquelles il y a invariance d'échelle, c'est-à-dire une évolution linéaire des estimateurs en représentation log-log, sont estimées en appliquant un algorithme de segmentation de nuage de points ([D'Errico, 2017](#)). Celui-ci se base sur la régression non-linéaire de courbes "spline" (fonctions polynomiales par morceaux),

permettant d'estimer la position des ruptures de pente au sein des estimateurs statistiques (un exemple d'application détaillée de cet algorithme est présenté en Annexe C). Ainsi, ces ruptures d'échelle définissent les bornes  $l_{min}$  et  $l_{max}$  de chaque gamme d'échelles détectée.

#### 4) Estimation des paramètres d'échelle :

Enfin, les paramètres d'échelle  $\beta, H, \alpha, C_1$  sont estimés pour chacune des gammes d'échelles. De même, le coefficient de détermination  $R^2$  et l'intervalle de confiance à 95%  $\delta$  issus des régressions linéaires de chaque estimateur sont calculés et utilisés en tant qu'indicateurs de qualité de la loi d'échelle.

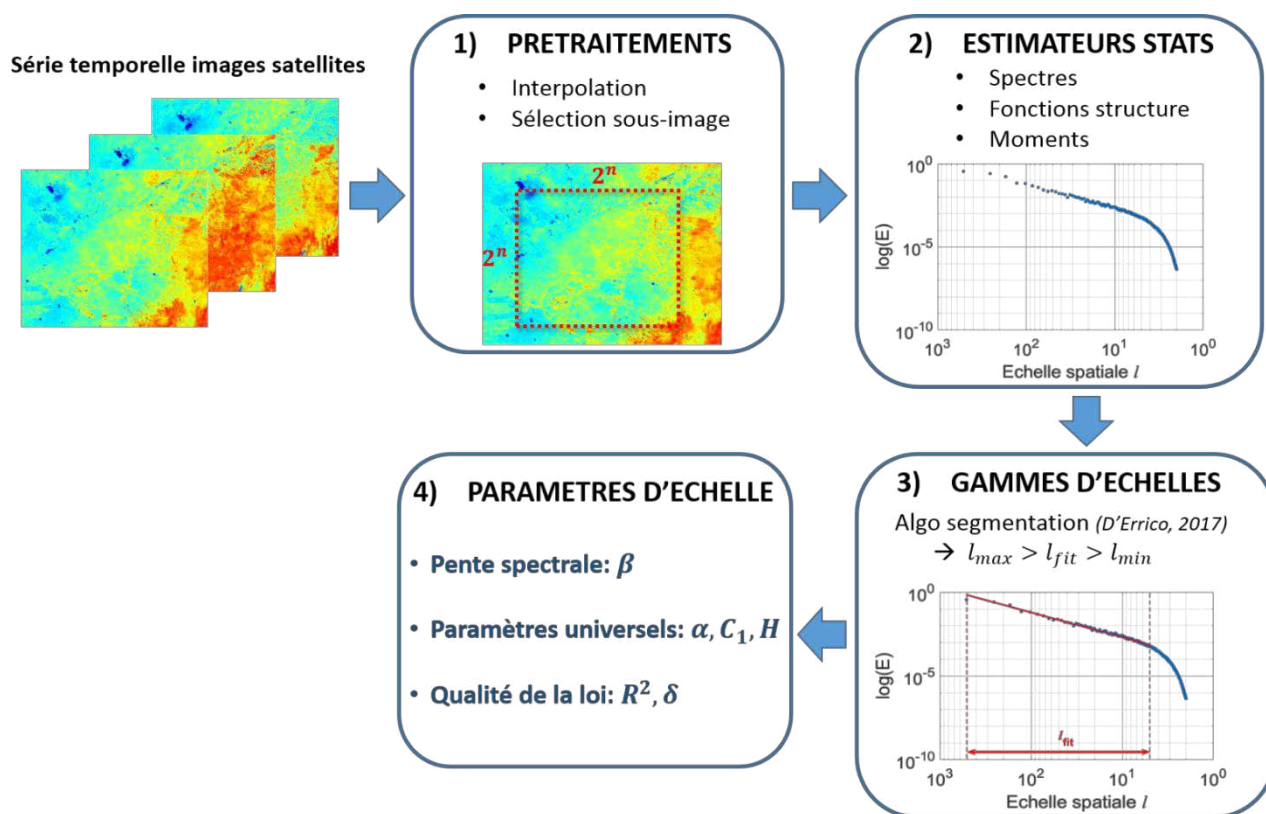


Figure 2.34 : Méthodologie générale pour l'analyse multi-échelle de séries temporelles d'images satellites.

Nous verrons dans les chapitres suivants que cette méthodologie d'analyse nous permettra d'avoir accès à deux types de comportement multi-échelle. En effet, il faut bien voir que les jeux de données analysés dans la suite seront constitués de séries d'images. L'analyse décrite ci-dessus permet donc d'accéder à des estimateurs de spectre, de fonctions de structure et de moments pour chaque image. Nous avons donc le choix, après l'étape 2 ci-dessus, entre garder cette information pour chaque image, ou au contraire calculer la moyenne de chaque estimateur sur l'ensemble de la période (moyenne sur  $N$  images). Nous procéderons donc en deux temps. **D'une part, nous étudierons le comportement multi-échelle moyen de chaque produit sur l'ensemble de la période d'étude.** Pour cela, nous calculerons la moyenne des  $N$  estimateurs obtenus après l'étape 2 de manière à avoir : un spectre moyen, deux fonctions de structure moyennes (une pour chaque axe) et les différents moments statistiques moyens (un pour chaque ordre  $q$ ). Cela nous permettra de déterminer des paramètres d'échelle moyens représentatifs de l'ensemble de la période étudiée. **D'autre part, nous analyserons également les propriétés multifractales date par date de nos produits.** Dans ce cas, nous conserverons les estimateurs statistiques obtenus pour chaque image, ce qui nous permettra d'estimer des paramètres d'échelle à chaque date disponible. De cette manière, nous aurons accès à l'évolution temporelle des propriétés multifractales des produits étudiés. Cette démarche présente un intérêt potentiel pour la mise en évidence de l'impact de phénomènes tels que des cycles saisonniers par exemple.

# 3 Analyse multi-échelle d'un algorithme de désagrégation déterministe d'humidité du sol : DisPATCh

---


Ce chapitre présente les travaux menés au cours de cette thèse sur l'analyse multi-échelle de l'algorithme de désagrégation d'humidité du sol DisPATCh. Cette étude a été réalisée sur des données acquises en Australie, de juin à décembre 2010. L'objectif de ces travaux est d'étudier les propriétés multifractales des produits d'entrée et de sortie de DisPATCh, afin de proposer une méthode de validation de l'algorithme en termes de comportement multi-échelle. Une première partie introductive portera sur la variabilité spatiale de l'humidité du sol. Plus particulièrement, nous présenterons les diverses techniques d'acquisition, de désagrégation et d'analyse multi-échelle utilisées dans la littérature pour étudier l'humidité du sol. Ensuite, une deuxième partie sera consacrée à la description de l'algorithme DisPATCh, des données satellites analysées ainsi que de la région d'étude. Dans une troisième partie, nous présenterons les résultats de l'analyse multifractale des produits d'entrée et de sortie de DisPATCh. Puis, nous terminerons ce chapitre par une discussion de ces résultats et une conclusion proposant des perspectives possibles pour la suite de cette étude. Nous informons le lecteur qu'une synthèse des travaux présentés dans ce chapitre a été publiée dans la revue *Advances in Water Resources* ([Neuhauser et al., 2019](#)).

## 3.1 Introduction

### 3.1.1 Variabilité spatiale de l'humidité du sol


L'humidité du sol est un élément clé du système climatique qui présente une forte hétérogénéité à plusieurs échelles temporelles et spatiales. Les interactions entre la surface terrestre et l'atmosphère, telles que l'eau, l'énergie et les flux de carbone, sont fortement liées à l'humidité du sol ([Ochsner et al., 2013](#)). Celle-ci joue un rôle important dans le cycle de l'eau (fig.3.1) car sa variabilité influe sur les processus de ruissellement, de drainage (infiltration) et d'évapotranspiration (processus combinant évaporation de l'eau du sol et transpiration de la végétation). Un des principaux forçages de l'humidité du sol est la pluie, mais il existe d'autres processus comme la remontée d'eau de nappes phréatiques qui peuvent induire une augmentation des niveaux d'humidité de la surface. Ainsi, l'humidité du sol est une variable importante dans plusieurs domaines scientifiques tels que l'hydrologie ([Western et al., 2004](#)), la météorologie ([Dai et al., 2004](#)), la climatologie ([Anderson et al., 2007](#)) et la gestion des ressources en eau ([Engman, 1991](#)).





**Figure 3.1 : Effets de l'humidité du sol sur les flux d'eau à l'interface terre-atmosphère (d'après Molero, 2017).**

L'humidité du sol est une variable géophysique qui intervient sur une large gamme d'échelles spatiales. Elle a une influence sur les grandes échelles continentales allant jusqu'à plusieurs centaines de kilomètres, et sur des échelles bien plus petites telles que les bassins versants ou les parcelles agricoles au sein desquelles l'humidité peut atteindre une variabilité centimétrique. Ainsi, l'hétérogénéité spatiale de l'humidité du sol est due à des facteurs environnementaux (fig.3.2) impactant cette dernière sur des gammes d'échelles spécifiques (Brocca et al., 2007; Crow et al., 2012; Jana, 2010; Vereecken et al., 2014). Les propriétés de texture et de structure du sol jouent sur l'hétérogénéité fine échelle de l'humidité, présente au niveau des parcelles agricoles par exemple (*field scale*). La topographie influe sur des échelles plus larges correspondant à celles des bassins versants (*watershed scale*). L'occupation du sol et les conditions météorologiques impactent quant à elle les échelles régionales et continentales.



**Figure 3.2 : Echelles d'impact des facteurs environnementaux sur la variabilité spatiale de l'humidité du sol (d'après Peng et al., 2017; Crow et al., 2012; Jana, 2010).**

Diverses techniques ont été développées à ce jour pour mesurer la variabilité de l'humidité du sol. Les mesures "terrain" (ou in-situ) permettent d'acquérir des jeux de données à très haute résolution, pouvant atteindre des échelles de l'ordre du centimètre en spatial et de la minute en temporel (Dobriyal et al., 2012; Robinson et al., 2008; Robock et al., 2000). Bien que ces méthodes soient reconnues comme fiables et faciles à mettre en œuvre, elles ne sont pas adaptées pour représenter l'hétérogénéité spatiale de l'humidité du sol aux échelles régionale et continentale. **La télédétection est une méthode d'acquisition qui permet d'accéder à ces échelles, fournissant des données régulières sur une large gamme d'échelles spatiales.**

### 3.1.2 Apport de la télédétection pour le suivi de l'humidité du sol


La variabilité de l'humidité du sol aux échelles régionales et globales peut être acquise et étudiée à l'aide de la télédétection spatiale. Différents satellites embarquant des capteurs micro-ondes actifs ou passifs permettent de mesurer quotidiennement l'humidité du sol de surface, c'est-à-dire le taux d'humidité située dans les cinq premiers centimètres de la colonne sol (Petropoulos et al., 2015; Wigneron et al., 2003). La mesure de cette quantité se base sur la relation entre la constante diélectrique du sol et son contenu en eau. Les capteurs micro-ondes actifs (ou radars) mesurent l'énergie réfléchi par le sol après avoir émis une impulsion électromagnétique vers la surface. Parmi les plus connus, nous pouvons citer le capteur ASCAT (Advanced Scatterometer; Bartalis et al., 2007) ainsi que le radar embarqué sur le satellite Sentinel-1 de l'ESA (European Space Agency) (Wagner et al., 2009). Ces deux capteurs fonctionnent en bande C, c'est-à-dire pour des ondes dont la fréquence est comprise entre 4 et 8 GHz, et ont accès à des échelles spatiales pouvant atteindre quelques mètres dans le cas de Sentinel-1 (tableau 3.1).

Leur principal inconvénient est leur sensibilité à la végétation et à la rugosité de surface, ce qui peut altérer l'information utile (taux d'humidité) présente dans le signal mesuré. Les capteurs micro-ondes passifs (ou radiomètres) sont quant à eux moins sensibles aux conditions de diffusion. Ces capteurs mesurent les radiations propres de la surface émises vers l'espace, également appelées "température de brillance". De bons résultats ont été obtenus avec des radiomètres à bande C et X (8 – 12 GHz) tels que le capteur AMSR-E (Advanced Microwave Scanning Radiometer-Earth; Njoku et al., 2003; Owe et al., 2001), ou par des radiomètres bande-L (1 – 2 GHz) tels que ceux embarqués dans les satellites SMOS (Soil Moisture and Ocean Salinity; Kerr et al., 2010) et SMAP (Soil Moisture Active Passive; Entekhabi et al., 2010a).

Capteur	Type d'acquisition	Résolution	Répétitivité	Bande
ASCAT	ACTIF	25-50 km	2 jours	C
Sentinel-1		5-20 m	6-12 jours	C
AMSR-E	PASSIF	25-50 km	2 jours	C - X
SMOS		30-55 km	3 jours	L
SMAP		40 km	2-3 jours	L

**Tableau 3.1 : Description des principaux capteurs satellites par micro-ondes actives et passives dédiés à l'acquisition de l'humidité du sol.**

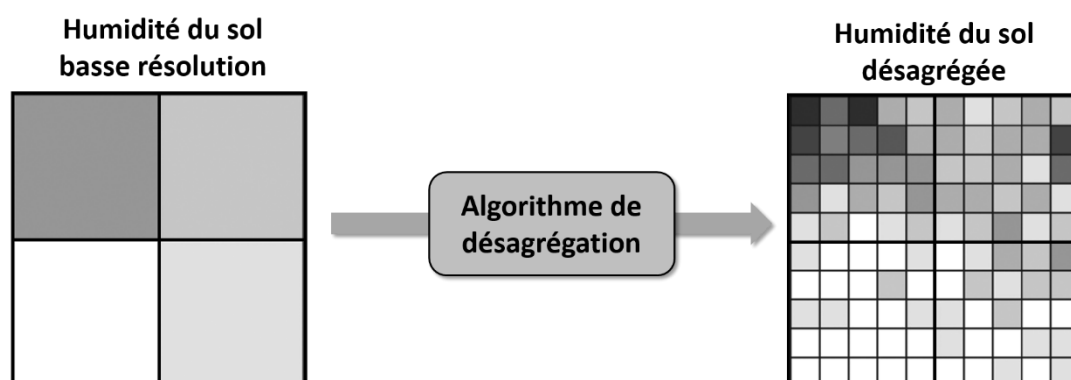
En bande L, la température de brillance acquise par les capteurs micro-ondes présente l'avantage d'être peu sensibles à la végétation (fig.3.3), ce qui permet d'estimer de manière optimale l'humidité du sol pour des conditions d'occupation du sol plus variées que dans le cas des bandes C et X. Les missions satellitaires en bande L fournissent des produits d'humidité avec un temps de visite de 2 à 3 jours. Cependant, en raison de contraintes technologiques, **la résolution spatiale des capteurs en bande L est faible** (30–55 km), correspondant à des échelles spatiales bien plus grandes que l'échelle kilométrique. Cela peut s'avérer contraignant dans certains cas, notamment pour des applications hydro-agricoles nécessitant une résolution plus fine, infra-kilométrique (Walker et Houser, 2004). Pour remédier à ce problème, des **méthodes de désagrégation ont été créées pour améliorer la faible résolution spatiale des données satellitaires.**



**Figure 3.3 : Sensibilité des capteurs micro-ondes à l'humidité du sol en bande L (1.4 GHz). La végétation et l'atmosphère ont peu d'effet sur la mesure du signal (Kerr, communication interne).**

### 3.1.3 Désagrégation spatiale pour l'étude fine échelle de l'humidité du sol

Diverses méthodes ont été développées pour améliorer la résolution spatiale des données satellites d'humidité du sol. Ces méthodes se présentent sous la forme d'algorithmes opérationnels dits de "désagrégation" ou "super-résolution" qui divisent chaque pixel constituant les produits d'origine en plusieurs pixels de tailles plus petite (fig.3.4). Ces algorithmes diffèrent les uns des autres selon leurs données d'entrée (produits satellites, données auxiliaires, etc.) et le type d'approche qui peut être physique ou statistique. Dans la suite de ce chapitre, nous utiliserons les termes "basse résolution" pour désigner la résolution spatiale des données d'origine utilisées en entrée de l'algorithme, et "haute résolution" pour définir les données désagrégées. Cela ne signifie pas que ces dernières sont de manière absolue à haute résolution, mais plutôt qu'elles sont à résolution plus élevée que les données d'origine non désagrégées.



**Figure 3.4 : Schéma de principe de la désagrégation de données spatialisées d'humidité du sol.**

#### 3.1.3.1 Les différentes méthodes de désagrégation de l'humidité

Selon la classification proposée par [Peng et al. \(2017\)](#), nous pouvons trouver quatre groupes principaux de méthodes de désagrégation (voir tableau 3.2 pour un résumé de ces groupes et méthodes) :

##### 1) *Micro-ondes passives et radar* :

Le premier groupe rassemble les techniques de désagrégation qui combinent les produits satellites acquis par micro-ondes passives avec des données satellites radars. Ces dernières sont ainsi utilisées comme des données "auxiliaires", dont la résolution spatiale est meilleure que les données passives. Par exemple, nous pouvons citer la méthode par "détection de changement" proposée par [Njoku et al. \(2002\)](#). Cette méthode réalise la combinaison de données micro-ondes passives basse résolution et micro-ondes actives haute résolution en se basant sur la relation linéaire entre humidité du sol et signal radar rétrodiffusé

(supposant l'invariance temporelle de la végétation et des effets de rugosité de surface). Cette méthode a été appliquée dans d'autres travaux tels que [Narayan et al. \(2006\)](#) et [Piles et al. \(2009\)](#) qui ont montré l'efficacité de la méthode pour améliorer la précision des données d'humidité du sol.

Des outils statistiques ont également été utilisés pour combiner les produits actifs et passifs, tels que des méthodes de fusion Bayésiennes ([Zhan et al., 2006](#)), ou les méthodes d'amélioration d'image basée sur les ondelettes ([Montzka et al., 2016](#)). Ce type d'approche a montré le potentiel des données radars pour améliorer la résolution de l'humidité du sol, et ce même dans des conditions d'acquisition parfois difficiles. En particulier, ces approches fonctionnent également lorsque le contenu en eau de la végétation peut s'avérer élevé et pour différents types de couvert végétal ([Akbar et Moghaddam, 2015](#)). Néanmoins, une limitation de ce premier groupe de méthode est le décalage temporel qui peut exister entre les données actives et passives, lié à la faible répétitivité des données radars. Récemment, le satellite SMAP a été lancé pour contourner ce problème en intégrant à son bord à la fois un radiomètre et un radar ([Das et al., 2011](#)). Malheureusement, le capteur radar a cessé de fonctionner et aucune combinaison active/passive n'a pu être réalisée. Cependant, les précédentes études menées pour préparer la mission ont confirmé le potentiel de la fusion de ces données pour améliorer la résolution spatiale des produits satellites d'humidité du sol.

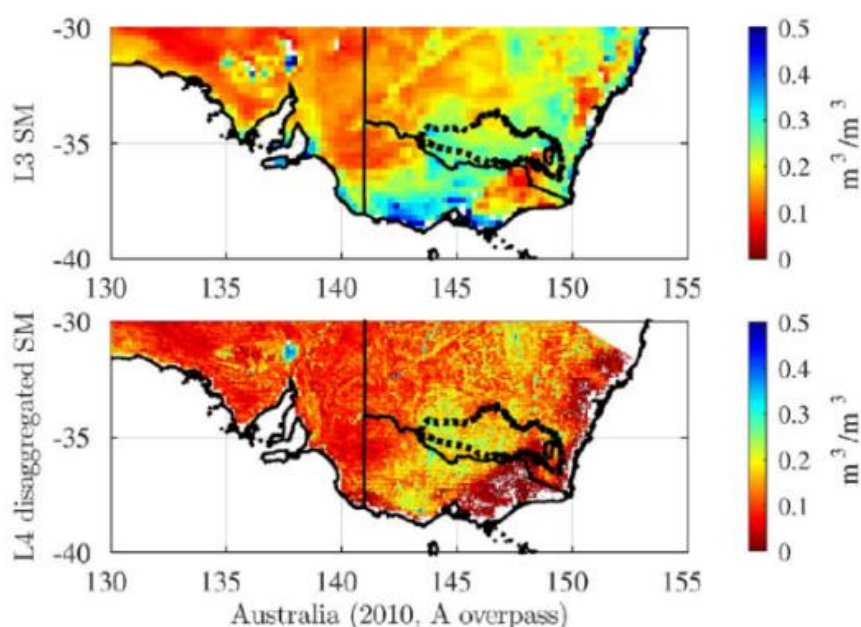
## 2) *Micro-ondes passives et données optiques/thermiques :*

D'autres types de données auxiliaires peuvent être combinés aux micro-ondes passives. Il s'agit des données de télédétection optiques et thermiques. Celles-ci ont l'avantage d'avoir à la fois une bonne répétitivité temporelle et une haute résolution spatiale. Plus particulièrement, ce deuxième groupe de méthode utilise des produits de végétation, de température de surface et d'albédo (pouvoir réfléchissant de la surface) définis à haute résolution pour désagréger l'humidité du sol. Ces méthodes se basent sur les travaux de [Carlson et al. \(1994, 2007\)](#) puis de [Zhan et al. \(2002\)](#) et [Chauhan et al. \(2003\)](#) qui consistent à relier, au moyen d'une fonction polynomiale, l'humidité du sol haute résolution à la fraction de végétation et la température du sol. Ces dernières sont obtenues respectivement à partir des produits de télédétection NDVI (Normalized Difference Vegetation Index) et LST (Land Surface Temperature) définis tous deux à haute résolution.

Une version améliorée de l'approche a ensuite été proposée par [Piles et al. \(2011\)](#). Celle-ci consistait à remplacer les données d'albédo par des températures de brillance, ce qui montra de meilleurs résultats après comparaison des données désagrégées aux mesures in-situ. A titre d'exemple, cette technique de désagrégation a été appliquée pour améliorer la résolution de l'humidité acquise par le capteur AMSR-E, en la combinant avec des données optiques/thermiques mesurées à partir du capteur MODIS (MODerate resolution Imaging Spectroradiometer) ([Choi and Hur, 2012](#)) ou du capteur MSG-SEVIRI (Meteosat Second Generation Enhanced Visible and Infrared Imager) ([Zhao and Li, 2013](#)). Le principal problème

dans cette méthodologie est que les variations basses fréquences (larges échelles) de l'humidité d'origine ne sont pas conservées dans le produit d'humidité désagrégée.

Basées sur le même principe, d'autres algorithmes de désagrégation ont été développés pour relier l'humidité haute résolution à l'humidité basse résolution. C'est le cas de l'algorithme opérationnel DisPATCh (Disaggregation based on Physical And Theoretical scale Change; [Merlin et al., 2008a](#); [Molero et al., 2016](#)). Cet algorithme est davantage physique car il se base sur des processus d'évaporation du sol pour connecter les données optiques/thermiques et l'humidité du sol (voir section 3.2.4 pour plus de détails sur l'algorithme). Différentes applications de DisPATCh ont été réalisées pour améliorer les ~ 40 km de résolution de l'humidité SMOS. En effet, une résolution de 1 km a pu être obtenue à partir de données MODIS ([Merlin et al., 2012](#); [Molero et al., 2016](#); fig.3.5), et même pouvant atteindre 100 m lors de la combinaison avec des produits Landsat-7/8 ([Merlin et al., 2013](#); [Ojha et al., 2019](#)). L'originalité de la méthode réside dans l'estimation d'une variable représentative (proxy) de l'humidité du sol qui est appelée Efficacité Évaporative du Sol. Cette dernière a l'avantage, par rapport à la température de surface du sol ou à l'évapotranspiration, d'être plus connectée à l'humidité du sol et d'être peu variable pendant la journée. Certaines améliorations doivent encore être apportées à la modélisation de l'efficacité évaporative utilisée dans DisPATCh, notamment vis-à-vis des effets de pente liés au relief ([Malbêteau et al., 2017](#)) ou concernant les propriétés du sol ainsi que les conditions atmosphériques ([Merlin et al., 2016](#)).



*Figure 3.5 : Produits moyens d'humidité du sol acquis par le satellite SMOS (L3 SM) et désagrégés par l'algorithme DisPATCh (L4 disaggregated SM) pour la période 06/2010-05/2011, sur la partie Sud-Est de l'Australie (d'après [Molero et al., 2016](#)).*



Pour terminer sur ce deuxième groupe de méthodes, des techniques comparables, également basées sur l'évaporation, ont été développées faisant intervenir des proxys différents tels que l'indice d'humidité du sol (Soil Wetness Index) (Kim et Hogue, 2012) ou alors un indice révélant l'état de la température et de la végétation (Vegetation Temperature Condition Index) (Peng et al., 2016), tous deux appliqués dans la méthode de désagrégation UCLA. De même, nous pouvons également citer des algorithmes améliorant directement la résolution des produits de température de brillance (à la place de l'humidité du sol), basés sur la relation entre la variabilité journalière de la température du sol et la moyenne de l'humidité (Song et al., 2014).

De manière générale, l'avantage de ces méthodes de désagrégation réside dans la cohérence temporelle entre les différents produits fusionnés (pas ou peu de décalage temporel). Cependant, certaines limitations existent. En effet, les capteurs optiques/thermiques sont sensibles aux nuages, rendant l'application de ces méthodes possible uniquement lorsque la couverture nuageuse est minimale voire nulle (Djamai et al., 2016).

### 3) *Données de géo-information :*

Une autre possibilité pour améliorer la résolution de l'humidité du sol est de bénéficier de la haute résolution de données de géo-information. Géo-référencées, ces données renseignent avec précision sur les propriétés locales de la scène étudiée telles que la topographie, la structure du sol, les caractéristiques de la végétation, etc. qui sont en lien direct avec l'humidité du sol (Werbylo and Niemann, 2014). La topographie, par exemple, fut souvent utilisée dans les algorithmes de désagrégation comme donnée auxiliaire permettant notamment de générer des produits spatialisés (sous forme de grille) à partir de données in-situ ponctuelles d'humidité du sol (Busch et al., 2012; Pellenq et al., 2003). Cependant, la plupart de ces méthodes se basent sur des mesures terrain, qui sont spécifiques à la zone étudiée. Ainsi, l'application est limitée à des échelles locales, rendant ces méthodes de désagrégation inadaptées pour l'étude large échelle de l'humidité du sol.

### 4) *Désagrégation basée sur des modèles :*

Le quatrième groupe concerne les méthodes de désagrégation basées sur des modèles. Ces derniers peuvent être de deux types. D'une part, nous trouvons les modèles hydrologiques de surface. Ceux-ci sont fortement dépendants de la zone d'application car ils essaient de relier l'humidité du sol satellite basse résolution à des paramètres haute résolution obtenus à partir de modèles de surface locaux. Dans ce cas, la désagrégation est réalisée par techniques d'optimisation (Ines et al., 2013), régressions linéaires (Loew and Mauser, 2008) ou relations bivariées (Verhoest et al., 2015).

D'autre part, il existe des modèles qui analysent et décrivent les statistiques de l'humidité en fonction de l'échelle spatiale. Ces modèles sont plus génériques et cherchent à préserver les propriétés statistiques à travers les échelles. Par exemple, Kaheil et al. (2008)

ont proposé une méthode de désagrégation basée sur les ondelettes servant à modéliser les propriétés spatiales statistiques de l'humidité haute résolution grâce à des données aéroportées d'humidité du sol acquises par le radiomètre ESTAR (Electronically Scanned Thinned Array Radiometer). D'autres approches utilisent les propriétés fractales de l'humidité du sol. Sur ce principe, [Bindlish and Barros \(2002\)](#) ont proposé une méthode "d'interpolation fractale" qu'ils ont appliquée aux produits d'humidité ESTAR. Ils ont utilisé le spectre de puissance pour représenter le comportement fractal de l'humidité, et ainsi améliorer la résolution spatiale de 200 m à 40 m. Quelques années plus tard, [Mascaro et al. \(2010\)](#) ont appliqué le modèle de cascades multifractales Log-Poisson (cf. section 2.2.2) à des données satellites d'humidité du sol pour générer des simulations à haute résolution. La difficulté avec les approches fractales est de préserver la non-stationnarité de l'humidité des larges échelles vers les fines échelles. Néanmoins, certaines études tentent de surmonter ce problème. Par exemple, [Kim and Barros \(2002a\)](#) ont adapté la méthode d'interpolation fractale en appliquant une fenêtre glissante sur des parties spécifiques de l'image d'origine. De cette manière, ils ont pu simuler la variabilité fractale de l'humidité en tenant compte de ses statistiques locales.

GROUPES	METHODES	TRAVAUX	PRODUITS D'ENTREE	Amélioration de la résolution
MICRO-ONDES PASSIVES + RADAR	Détection de changement	Narayan et al., 2006 Piles et al., 2009	Micro-ondes acquises par le radiomètre/radar bande-L PALS (aéroporté)	400 m → 100 m
	Fusion Bayésienne	Zhan et al., 2006	Micro-ondes simulées Hydros	40 km → 10 km
MICRO-ONDES PASSIVES + OPTIQUE/THERMIQUE	Fonction polynomiale	Choi and Hur, 2012 Zhao and Li, 2013	AMSR-E + MODIS AMSR-E + MSG-SEVIRI	25 km → 1 km 25 km → 15 km
	DisPATCh	Merlin et al., 2012 Ojha et al., 2019	SMOS + MODIS SMAP + Landsat-7/8	40 km → 1 km 40 km → 100 m
	Méthode UCLA	Peng et al., 2016	Données ESA CCI + MODIS	30 km → 5 km
DONNEES DE GEO-INFORMATION	Rélation statistique entre données auxiliaires de surface et humidité du sol	Pellenq et al., 2003	Topographie + mesures in-situ humidité	génération d'une grille à 20 m
MODELES	Ondelettes	Kaheil et al., 2008	ESTAR (aéroporté) + mesures in-situ humidité	800 m → 50 m
	Interpolation fractale	Kim and Barros, 2002	ESTAR	10 km → 1 km
	Cascades log-Poisson	Mascaro et al., 2010	ESTAR	25 km → 800 m

**Tableau 3.2 : Description des principales méthodes de désagrégation de l'humidité du sol.**

### 3.1.3.2 Intérêt et évaluation de la méthode DisPATCH

Les différentes méthodes de désagrégation décrites ci-dessus ont leurs propres avantages et inconvénients, et sont plus ou moins performantes selon le type de surface et les conditions climatiques. **Dans cette étude, nous nous intéressons à l'évaluation de la variabilité multi-échelle des produits d'humidité du sol générés par la méthode DisPATCH.** Malgré ses limitations liées à la présence de nuages, cet algorithme de désagrégation "semi-physique" bénéficie d'une faible sensibilité à la végétation grâce aux micro-ondes en bande L, de données auxiliaires optiques/thermiques à résolution kilométrique, et a l'avantage d'être dispensé des erreurs d'estimation couramment produites par les méthodes de désagrégation basées sur des modèles de surface (Peng et al., 2017).

Plusieurs études ont été réalisées à ce jour pour évaluer et valider la méthode DisPATCH (Malbêteau et al., 2016; Merlin et al., 2013, 2015; Molero et al., 2016). De manière générale, l'évaluation des algorithmes de désagrégation est réalisée en comparant les produits désagrégés aux mesures terrain. Pour cela, différents indicateurs de performances sont utilisés, tels que la corrélation, l'erreur quadratique moyenne ou le biais (Albergel et al., 2013; Al Bitar et al., 2012; Entekhabi et al., 2010b). Plus récemment, Merlin et al. (2015) ont proposé un nouvel indicateur qui estime l'apport ou gain de la méthode en termes de représentativité des données désagrégées par rapport aux données non-désagrégées. Pour prendre en compte la différence d'échelle spatiale entre les produits satellites désagrégés et les mesures terrain, des techniques de mise à l'échelle ("upscaling" en anglais) ont été développées afin de ramener les données désagrégées et les mesure in-situ à une échelle intermédiaire commune (Crow et al., 2012). Par exemple, Merlin et al. (2013) ont appliqué l'algorithme DisPATCH sur des données SMOS en utilisant d'une part des produits MODIS et d'autre part des produits Landsat-7 comme données auxiliaires. Les données SMOS basse résolution, les données désagrégées et les mesures terrain agrégés ont été comparées à trois échelles différentes : 40 km, 3 km et 100 m. De bons résultats ont confirmé le potentiel de DisPATCH pour améliorer la corrélation spatio-temporelle des produits satellites d'humidité du sol avec les mesures in-situ. De manière à valider les produits de télédétection, certains travaux tels que ceux de Molero et al. (2018) proposent de nouvelles méthodes permettant d'analyser et de caractériser la représentativité spatiale de données d'humidité terrain au sein de l'empreinte du satellite ou des produits désagrégés. Cependant, l'inconvénient de ces techniques de validation est qu'elles sont limitées à des échelles spécifiques. Ainsi, la caractérisation des produits d'humidité désagrégée sur un continuum d'échelles spatiales n'a pas encore été entièrement explorée. **C'est pourquoi, l'analyse des propriétés statistiques multi-échelles de ces produits pourrait fournir des informations pertinentes quant à la caractérisation de l'algorithme DisPATCH.**

### 3.1.4 Etudes statistiques multi-échelles de l'humidité du sol

Durant les trente dernières années, de nombreuses études ont été menées pour décrire les propriétés statistiques de l'humidité du sol à travers les échelles spatiales (Famiglietti et al., 2008; Rodriguez-Iturbe et al., 1995). Pour cela, différentes techniques ont été proposées, la plupart étant basées sur l'analyse de texture (cf. section 2.1.3). Les plus couramment utilisées sont les analyses spectrales et les analyses par ondelettes (Si, 2008), ainsi que l'analyse multifractale (Kim and Barros, 2002b; Ko et al., 2016; Mascaro et al., 2010; Oldak et al., 2002). En 1995, Rodriguez-Iturbe et al. ont mis en évidence pour la première fois le comportement fractal de l'humidité du sol acquise par télédétection : la variance spatiale de l'humidité suivait une loi puissance en fonction de l'échelle d'agrégation (taille des pixels) allant de 30 m à 1 km (expérience *Washita* 1992, Etats-Unis). Des études ultérieures ont montré qu'un tel comportement d'échelle de la variance pouvait être étendu à une gamme d'échelles plus large : jusqu'à l'échelle régionale (Hu et al., 1997) et même à l'échelle continentale (Rötzer et al., 2015). Des travaux de recherche similaires ont montré qu'une extension de la zone d'étude (augmentation de la surface totale) induisait une augmentation de la variance de l'humidité selon une fonction en loi puissance (Famiglietti et al., 2008; Rötzer et al., 2015; Brocca et al., 2012). De plus, Oldak et al. (2002) ont montré que le comportement d'échelle de l'humidité pouvait être multifractal : la loi puissance était également applicable aux six premiers moments statistiques estimés à partir de produits aéroportés d'humidité du sol, pour des échelles allant de la centaine de mètres à la dizaine de kilomètres (expériences *Washita* 1992 et *Southern Great Plains* 1997, Etats-Unis). Par la suite, d'autres travaux de recherche sur la variabilité spatiale de l'humidité du sol ont pu confirmer les propriétés multifractales de cette dernière (Das and Mohanty, 2006; Kim and Barros, 2002b; Lovejoy et al., 2008b; Mascaro et al., 2010).

Par ailleurs, certaines études ont montré que les propriétés d'échelle de l'humidité du sol pouvaient dépendre du taux moyen d'humidité. En effet, en traçant la variance de l'humidité en représentation log-log, Rodriguez-Iturbe et al. (1995) et Manfreda et al. (2007) ont pu constater une augmentation de la pente de la courbe en périodes sèches, révélant les variations saisonnières de la loi d'échelle (Rötzer et al., 2015). De plus, il a été observé que la variabilité de l'humidité du sol n'était pas gouvernée par un unique comportement d'échelle mais par plusieurs régimes d'échelles correspondant à différentes gammes d'échelles. En effet, à l'échelle de la parcelle et des bassins versants, la variabilité de l'humidité est principalement reliée aux caractéristiques de la surface telles que les propriétés du sol ou la topographie, tandis qu'à des échelles plus larges celle-ci est impactée par des phénomènes météorologiques comme les précipitations ou l'évapotranspiration (Cayan and Georgakakos, 1995; Entin et al., 2000). Dans certains travaux, l'estimation des semi-variogrammes (Ryu and Famiglietti, 2006; Korres et al., 2015), spectres de puissance et moments statistiques (Kim and

[Barros, 2002b](#)) ont permis de révéler la présence de ruptures d'échelle situées près de l'échelle de transition entre le régime *fine échelle* (propriétés de la surface) et le régime *large échelle* (phénomènes météorologiques).

**Ainsi, les caractéristiques mentionnées ci-dessus montrent la complexité et le haut degré de non-linéarité de l'humidité du sol, dus à des processus hydrométéorologiques agissant à différentes échelles spatiales.** Cela confirme alors l'intérêt de mieux comprendre les comportements d'échelle de l'humidité du sol pour des applications telles que l'assimilation de données ou la désagrégation ([Rötzer et al., 2015](#)).

Dans cette partie introductive, nous venons de voir que la forte hétérogénéité spatiale de l'humidité du sol pouvait être acquise et analysée sur de larges gammes d'échelles grâce aux capteurs embarqués sur les satellites. En particulier, les radiomètres bande-L ont l'avantage d'être peu sensibles à la végétation, permettant une acquisition fiable de l'humidité du sol dans des conditions d'observation variées. Cependant, leur faible résolution spatiale peut s'avérer contraignante dans certaines applications. C'est pourquoi, des algorithmes de désagrégation ont été développés afin d'améliorer la résolution des données. Notamment, nous avons vu que l'algorithme DisPATCh présentait certains atouts en termes de résolution spatiale, répétitivité temporelle et fiabilité des données désagrégées, sous réserve d'une couverture nuageuse faible. Bien que de nombreuses études aient été menées pour évaluer cet algorithme, **nous proposons d'appliquer une méthode alternative et complémentaire qui permettrait d'apporter une caractérisation du produit désagrégé en termes de comportement d'échelle.** De plus, il n'existe pas à notre connaissance d'études portant sur l'analyse multifractale au sens du formalisme des Multifractales Universelles ([Schertzer and Lovejoy, 1987](#)) de données d'humidité du sol acquises par micro-ondes passives. **Ainsi, ce travail permettrait d'apporter une vision différente sur l'humidité du sol et ses propriétés spatiales.**

## 3.2 Cas d'étude et données

### 3.2.1 Processeur C4DIS : vers une couverture globale de l'humidité désagrégée

Les différents produits analysés dans cette étude correspondent aux données d'entrée et de sortie du processeur C4DIS (CATDS level-4 DISaggregation; [Molero et al., 2016](#)) qui inclut la première version opérationnelle de l'algorithme DisPATCh. Cette version est issue des différents travaux menés jusqu'à aujourd'hui fournissant les meilleures performances de traitement ([Merlin et al., 2010a](#) , [2010b](#) , [2013](#)). Le processeur C4DIS a pour vocation de délivrer des produits désagrégés d'humidité du sol SMOS sur l'ensemble du globe. Ainsi, chaque utilisateur peut avoir accès sur demande aux produits désagrégés sur des zones spécifiques de la Terre. Pour une description détaillée du fonctionnement et de l'architecture interne du C4DIS, nous invitons le lecteur à se référer à [Molero \(2018\)](#). La figure 3.6 présente les trois principaux modules de traitement qui composent le processeur :

1) *Le pré-processeur DII (DisPATCh Input Interface):*

Ce module prépare les données d'entrée nécessaires à la méthode DisPATCh (voir section 3.2.2). Les produits SMOS de niveau 3 et les données auxiliaires MODIS sont ré-échantillonnés et reprojetés sur la grille WGS84, qui est la grille finale sur laquelle sont présentés les produits désagrégés. Les différentes étapes de ré-échantillonnage et de reprojection sont importantes pour permettre un fonctionnement optimal de DisPATCh (voir section 3.2.3). De plus, tous les produits d'entrée sont divisés suivant le découpage en tuile des produits MODIS, découpage sous lequel les produits désagrégés seront également fournis.

2) *Le processeur central DisPATCh :*

Il s'agit du module central contenant la version opérationnelle de l'algorithme DisPATCh décrit en section 3.2.4.

3) *Le post-processeur DOI (DisPATCh Output Interface):*

Ce dernier module prépare les données de sortie désagrégées en les mettant au format NetCDF (utilisé notamment pour les produits d'entrée SMOS). Des derniers traitements sont également réalisés comme la mise à zéro des valeurs négatives (qui sont mathématiquement possibles dans DisPATCh) et une attribution de l'heure et du jour UTC correspondant (Universel Temps Coordonné) pour maintenir une cohérence avec les produits SMOS. Au final, le post-processeur fournit un produit SMOS désagrégé de niveau 4.



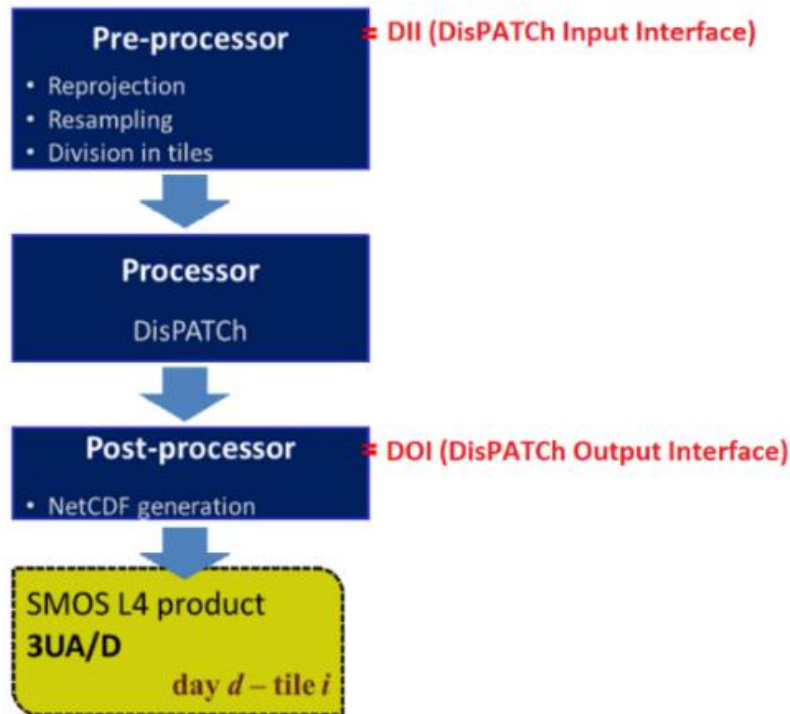


Figure 3.6 : Architecture générale du processeur C4DIS : le pré-processeur DII, le processeur central DisPATCh et le post-processeur DOI (d'après Molero, 2018).

## 3.2.2 Produits d'entrée du C4DIS

### 3.2.2.1 Les données globales d'humidité du sol SMOS

Le satellite SMOS a été lancé en 2009 par l'Agence Spatiale Européenne (ESA) afin de mesurer le taux d'humidité des surfaces continentales ainsi que la salinité des océans. Grâce à sa forte répétitivité temporelle de l'ordre du jour, il permet un suivi temporel fin et global de l'humidité du sol sur l'ensemble du globe. Il emporte à son bord le radiomètre interférométrique en bande L MIRAS (Microwave Imaging Radiometer with Aperture Synthesis; Kerr et al., 2010). La mesure du signal se base sur le principe de l'interférométrie qui consiste à utiliser l'information contenue dans les différences de phase du signal mesurées par plusieurs antennes distantes pour un même point. Ainsi, cela permet d'améliorer la faible résolution spatiale de l'instrument avec un encombrement du satellite plus faible.

Le capteur mesure par télédétection passive la température de brillance (TB) émise par la surface. Cette grandeur physique, exprimée en Kelvin, est proportionnelle à l'émissivité ( $e$ ) et à la température physique ( $T_{phys}$ ) de la surface observée :

$$TB = e \times T_{phys}$$

3.1

Cette relation n'est vraie qu'en bande L (approximation de Rayleigh-Jeans). Plus la surface est humide ou saline, plus son émissivité est faible, et donc plus la température de brillance est faible. Ainsi, nous avons accès, via la TB, à la contenance en eau de la surface détectée par SMOS.

Les données d'humidité du sol sont fournies par les produits journaliers SMOS de niveau 3 (référence : MIR CLF31A/D). Ces produits sont délivrés par le Centre Aval de Traitement des Données SMOS (CATDS), qui est le segment sol français dédié aux traitements des produits SMOS de niveaux 3 et 4. Via les mesures de TB, l'humidité du sol est acquise à une résolution spatiale variant entre 35 et 55 km, soit 40 km en moyenne, dépendant de l'angle de visée du satellite (Kerr et al., 2012; Wigneron et al., 2007). Les produits SMOS sont distribués sur la grille EASE (Equal Area Scalable Earth), avec un espacement de grille de 25 km × 25 km. Ainsi, dans le cas des données SMOS mais aussi pour tout autre produit satellite, nous ferons la différence entre la résolution radiométrique du capteur qui correspond à la surface au sol d'un point de mesure (~ 40 km pour SMOS) et la taille de chaque pixel (25 km) étant liée à la grille sur laquelle les produits sont projetés. Dans la suite du manuscrit, c'est cet espacement de grille que nous considérerons comme l'échelle  $l$  d'observation (échelle la plus réduite) de nos produits.

### 3.2.2.2 Les données auxiliaires MODIS

Le capteur optique MODIS permet un suivi quotidien des surfaces continentales, de l'océan et de l'atmosphère grâce à ses 36 bandes spectrales réparties du visible à l'infrarouge thermique (voir section 4.1.1 pour plus de détails sur la télédétection par capteurs optiques). Celui-ci est embarqué sur deux satellites américains Terra et Aqua, lancés respectivement en 1999 et 2002 par la NASA (National Aeronautics and Space Administration). Les données sont acquises avec une répétitivité temporelle de 1 jour, et une résolution spatiale pouvant se situer entre 250 m et 1 km selon les bandes d'acquisition.

Les données de températures de surface LST utilisées dans l'algorithme DisPATCH sont extraites des produits journaliers de niveau 3 : MYD11A1 (Aqua) et MOD11A1 (Terra). Ces produits de température sont estimés à partir des rayonnements émis par la surface de la Terre dans le moyen infrarouge et l'infrarouge thermique ( $3 - 15 \mu m$ ). Les deuxièmes données auxiliaires correspondent aux mesures de la couverture de végétation. Celles-ci sont fournies tous les 16 jours grâce aux produits de niveau 3 de NDVI issus du satellite Terra (MOD13A2). L'indice de végétation NDVI est calculé à partir des réflectances de surface acquises dans le rouge et le proche infrarouge (combinaison détaillée en section 4.2.2.4). Les deux produits LST et NDVI sont fournis à 1 km de résolution, par le centre d'archivage LP DAAC (Land Processes Distributed Active Archive Center) de la NASA. Ces produits sont présentés sur une grille sinusoïdale, avec un espacement de grille légèrement inférieur au kilomètre :  $0.93 \text{ km} \times 0.93$

km (Didan et al., 2015; Wan, 2006). Notons que les produits LST ont une répétitivité journalière, alors que les produits de NDVI sont représentatifs d'une période de 16 jours. Cela pourrait sembler contraignant dans le cas d'une application journalière de DisPATCh. Or, la végétation variant peu d'une semaine à l'autre, ces produits NDVI sont tout de même adaptés pour étudier l'évolution de la couverture végétale.

### 3.2.2.3 Autres données auxiliaires

Des données de topographie sont également utilisées dans le processeur C4DIS. Elles permettent de prendre en compte la diminution de la température de l'air avec l'altitude, pouvant ainsi affecter les phénomènes d'évaporation sur lesquels se basent la méthode de désagrégation (Merlin et al., 2013; Molero et al., 2016). Ces données sont fournies grâce au modèle numérique de terrain GTOPO30, distribué par le centre de données de l'USGS (United States Geological Survey). Ce modèle est défini sur une grille de type WGS84 et avec un espacement de grille de 30 secondes d'arc soit d'environ 1 km.


## 3.2.3 Produits désagrégés d'humidité du sol

Les produits de sortie de DisPATCh sont générés chaque jour par le processeur C4DIS. Ils ont une résolution correspondant à celle des produits MODIS (1 km) et sont présentés selon la grille WGS84, avec un espacement de grille de  $0.01^\circ$  soit environ 1.12 km. Par soucis de simplicité, nous considérerons par la suite l'approximation  $0.01^\circ = 1$  km.

A chaque date  $d$ , le produit final d'humidité du sol désagrégée est en fait obtenu en effectuant la moyenne de plusieurs images haute résolution. Chacune de ces images est issue de la désagrégation des produits SMOS à partir des données MODIS correspondant à plusieurs combinaisons différentes (Malbêteau et al., 2016; Merlin et al., 2012; Molero et al., 2016). La figure 3.8 présente la méthodologie générale qui consiste à combiner l'ensemble des produits d'entrée suivants :

#### 1) *Quatre images d'humidité SMOS sous-échantillonnées :*

L'objectif ici est de ramener les données d'humidité SMOS sur un espacement de grille équivalent à leur résolution radiométrique ( $\sim 40$  km). Pour cela, une fenêtre glissante définie sur une grille à 50 km d'espacement (deux fois plus espacée que celle d'origine) est appliquée sur le produit SMOS. Cette fenêtre est positionnée selon les quatre configurations schématisées en figure 3.7, générant ainsi quatre grilles sous-échantillonnées. Cette opération permet d'augmenter la couverture spatiale des produits d'entrée en comblant les éventuelles données manquantes.



**Figure 3.7 : Exemple d'extraction des quatre grilles sous-échantillonnées (lignes en pointillés) à partir de la grille originale SMOS (ligne pleine). Les pixels en gris correspondent aux valeurs à garder et à attribuer à chaque nouvelle grille (d'après [Malbêteau et al., 2016](#)).**

## 2) Six images LST MODIS :

Afin d'assurer une meilleure couverture temporelle, chaque image SMOS sous-échantillonnée est combinée avec six images LST. Celles-ci correspondent à des températures de surface acquises sur trois jours consécutifs ( $d - 1$ ,  $d$ ,  $d + 1$ ), et pour les deux satellites Aqua et Terra (fig.3.8). Cette opération fait l'hypothèse de la stabilité spatiale de l'humidité du sol sur une période de trois jours. De manière générale, cette hypothèse est vérifiée, mais il est important de noter que dans certains cas elle peut ne pas l'être, en particulier lors d'évènements intenses journaliers comme les précipitations ou les phénomènes d'irrigation.

## 3) Une image NDVI MODIS :

Pour ce qui est des données de végétation, une seule image de NDVI est utilisée dans l'algorithme de désagrégation. Comme évoqué précédemment, celle-ci représente l'état de la végétation sur une période de 16 jours. Ainsi, chaque paire d'images SMOS/LST est combiné avec la même image de NDVI sur les 16 jours correspondant.

En suivant cette méthodologie, chaque pixel haute résolution du produit final d'humidité désagrégée (nommé sm1k3d, fig.3.8) provient de la moyenne d'au maximum 24 pixels désagrégés (soit 24 paires SMOS/LST possibles). L'avantage de cette méthode combinatoire est que l'incertitude dans les données désagrégées peut être réduite et estimée ([Malbêteau et al., 2016](#)).




Figure 3.8 : Schéma de principe de la combinaison des différents produits SMOS et MODIS pour l'obtention d'un produit final d'humidité du sol désagrégée par l'algorithme DisPATCH (d'après Malbêteau et al., 2016).

### 3.2.4 L'algorithme DisPATCH

L'algorithme DisPATCH (fig.3.9) est fondé sur un modèle semi-empirique qui estime l'efficacité évaporative du sol SEE (Soil Evaporative Efficiency) à partir de données LST et NDVI à haute résolution ( $HR = 1 \text{ km}$ ). Dans un premier temps, la méthode consiste à extraire les composantes "sol"  $T_{s,HR}$  et "végétation"  $T_{v,HR}$  des données de température de surface LST. Pour cela, l'approche se base sur une variante de la méthode du trapèze proposée par Moran et al. (1994) qui interprète l'espace caractéristique défini par les données LST et des données de fraction de végétation  $f_{v,HR}$  (issues du NDVI). L'objectif ici est d'extraire la température du sol  $T_{s,HR}$  à partir des deux équations suivantes :

$$T_{s,HR} = (LST - f_{v,HR} * T_{v,HR}) / (1 - f_{v,HR}) \quad 3.2$$

$$f_{v,HR} = (NDVI - NDVI_{soil}) / (NDVI_{veget} - NDVI_{soil}) \quad 3.3$$

Dans l'équation 3.2, la température de la végétation  $T_{v,HR}$  est calculée d'après [Moran et al. \(1994\)](#).  $NDVI_{soil}$  and  $NDVI_{veget}$  en (3.3) sont les valeurs de NDVI correspondant à un sol nu (fixée à 0.15) et à un sol entièrement recouvert de végétation (fixée à 0.9).

Ensuite,  $SEE_{HR}$  à 1 km de résolution peut être estimée à partir de la température du sol  $T_{s,HR}$  selon la méthodologie proposée par [Merlin et al. \(2012\)](#) :

$$SEE_{HR} = (T_{s,max} - T_{s,HR}) / (T_{s,max} - T_{s,min}) \quad 3.4$$

où  $T_{s,max}$  et  $T_{s,min}$  sont des termes calculés selon l'approximation de [Merlin et al. \(2013\)](#) qui considère les relations entre la valeur minimum/maximum de LST et la fraction de végétation  $f_{v,HR}$  associée (plus de détails sur ces estimations dans [Molero et al., 2016](#); p.4).

**L'efficacité évaporative est utilisée pour décrire la variabilité spatiale de l'humidité du sol au sein des pixels basse résolution ( $LR = 40 \text{ km}$ ) des produits SMOS.** Ainsi, l'humidité du sol SM (Soil Moisture) définie à haute résolution est reliée à  $SEE_{HR}$  à travers le modèle linéaire proposé par [Budyko \(1956\)](#) et [Manabe \(1969\)](#) :

$$SEE_{HR} = \frac{SM_{HR}}{SM_p} \quad 3.5$$

où  $SM_p$  est un paramètre basse résolution dépendant des conditions atmosphériques et des propriétés du sol. Dans le processeur C4DIS, ce paramètre est calculé à basse résolution pour chaque date  $d$  d'application de DisPATCh, et ce à partir des produits journaliers d'humidité SMOS ( $SM_{LR}$ ) et des données de SEE agrégées à basse résolution ( $SEE_{LR}$ ) :

$$SM_p = \frac{SM_{LR}}{SEE_{LR}} \quad 3.6$$

La désagrégation est finalement réalisée en appliquant un développement de Taylor du premier ordre aux données de SEE et d'humidité du sol :

$$SM_{HR} = SM_{LR} + SM'(SEE_{LR}) \times (SEE_{HR} - SEE_{LR}) \quad 3.7$$

avec  $SM'(SEE_{LR})$  la dérivée partielle de l'humidité par rapport à la SEE basse résolution. Ici, cette dérivée correspond simplement au paramètre  $SM_p$  estimé selon (3.6).



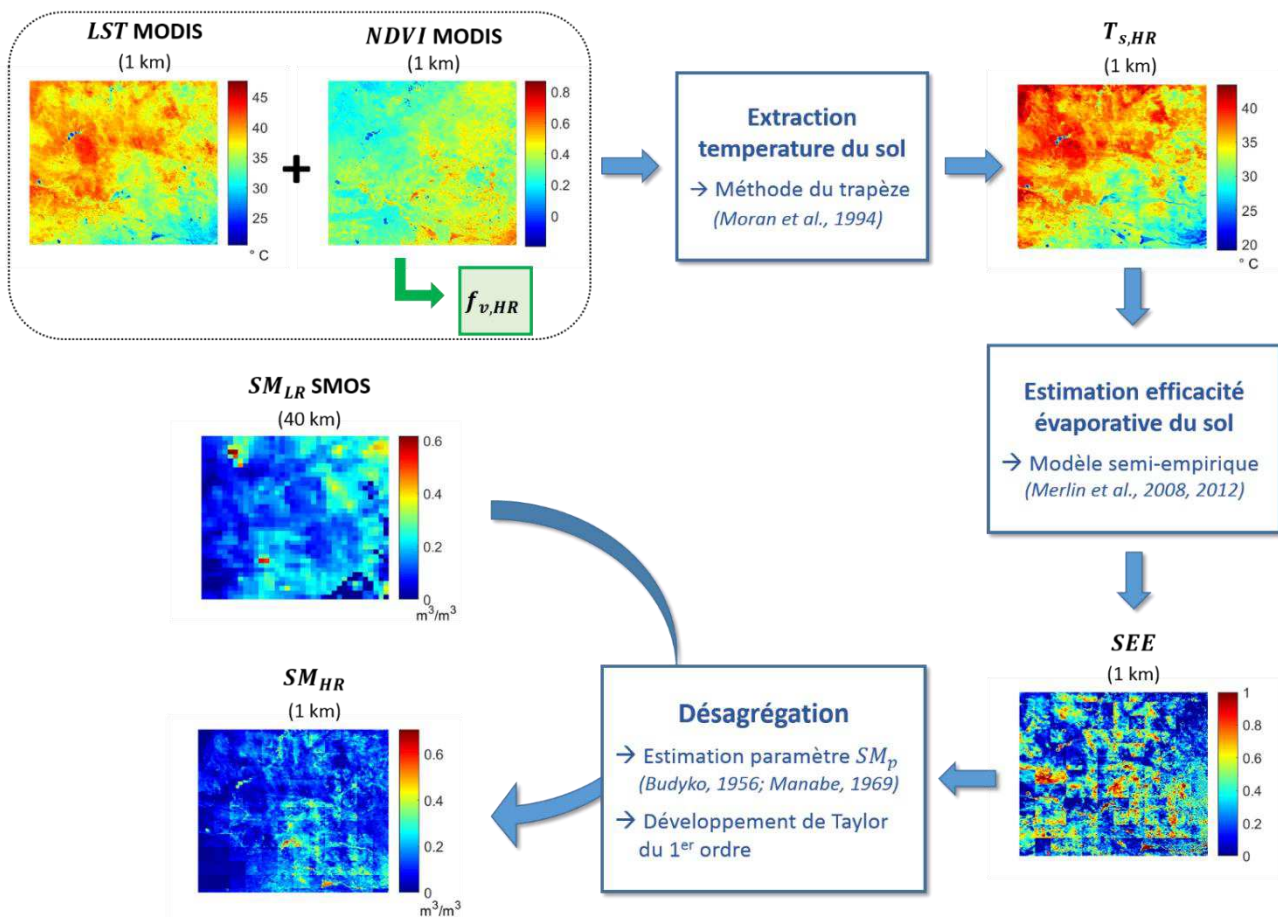


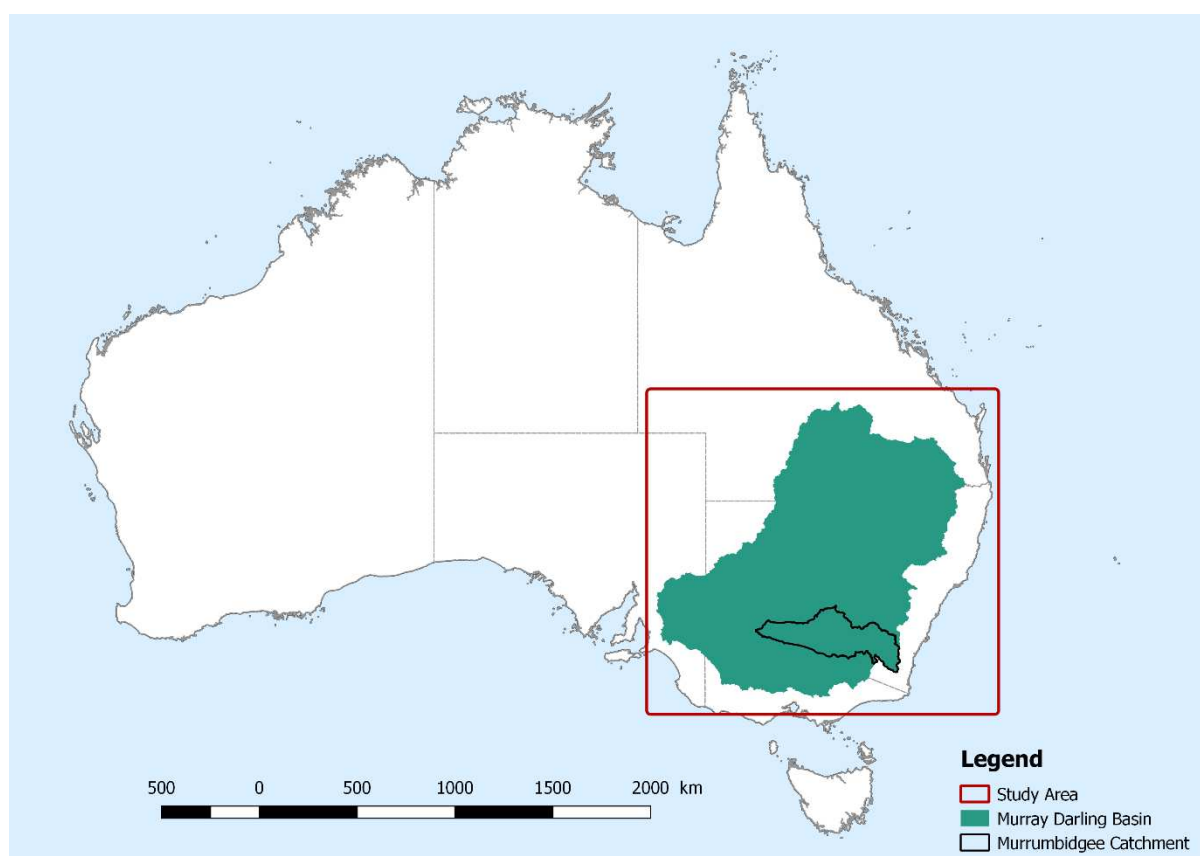
Figure 3.9 : Schéma de principe de désagrégation de l'humidité du sol par l'algorithme DisPATCH.

### 3.2.5 Zone d'étude

#### 3.2.5.1 L'étude de l'humidité du sol en Australie

L'Australie est un pays vaste, d'une superficie de près de 8 millions de km<sup>2</sup>, caractérisé par diverses conditions de surface et climatiques. **Il s'agit donc d'une zone propice à l'étude des variations spatiales de l'humidité du sol sur une large gamme d'échelles.** De nombreuses études sur l'humidité du sol ont été menées en Australie afin d'étudier sa variabilité à l'aide de données terrain, aéroportées et satellites (Smith et al., 2012). On peut citer, entre autres, les campagnes NAFE'06 (National Airborne Field Experiment 2006; Merlin et al., 2008b) et AACES (Australian Airborne Calibration/validation Experiments for SMOS; Peischl et al., 2012). Ces campagnes ont été réalisées sur le bassin versant du Murrumbidgee (82 000 km<sup>2</sup>, fig.3.10), situé dans la partie Sud-Est de l'Australie. En raison de ses conditions climatiques variables (humide à l'Est, semi-aride à l'Ouest), cette région a été utilisée pour la validation de missions satellites telles que SMAP (Panciera et al., 2014) ou SMOS. Les produits d'humidité du sol acquis par SMOS ont été évalués lors des campagnes AACES, qui se sont déroulées en 2010

sur deux périodes: janvier-février (AACES-1) et septembre (AACES-2). De vastes réseaux de mesures in situ (réseau de surveillance hydrologique OzNet; [Smith et al., 2012](#)) et des vols par transect (Polarimetric L-band Multibeam Radiometer; [Peischl et al., 2012](#)) ont été utilisés pour valider les données SMOS. Dans ce contexte, bénéficiant d'un jeu de données dense d'humidité du sol à différentes échelles spatiales, **les premières applications de l'algorithme DisPATCH ont été réalisées au cours des campagnes AACES** ([Merlin et al., 2012](#)). Ces travaux ont montré l'efficacité de DisPATCH dans les zones semi-arides à faible végétation et son potentiel pour évaluer les produits basse résolution SMOS. Par la suite, d'autres études scientifiques ([Malbêteau et al., 2016](#); [Molero et al., 2016](#)) ont poursuivi l'évaluation et l'amélioration de l'algorithme DisPATCH sur le bassin versant du Murrumbidgee.



*Figure 3.10 : Zone d'étude située au Sud-Est de l'Australie, incluant les bassins du Murray Darling et du Murrumbidgee (1 million km<sup>2</sup>).*

### 3.2.5.2 Le bassin du Murray Darling : une vaste région aux propriétés climatiques variées

Dans cette thèse, nous avons étudié les produits DisPATCh (entrées et sorties de l'algorithme) sur une période de 7 mois allant de juin à décembre 2010, en tirant parti des études antérieures de DisPATCh effectuées durant cette période. Nous avons choisi d'étendre la zone d'étude, du bassin versant du Murrumbidgee au bassin du Murray Darling (1 million de km<sup>2</sup>, fig.3.10). La première raison de ce choix est liée à l'objectif principal de cette étude, à savoir l'analyse sur une large gamme d'échelles spatiales des produits DisPATCh. **En élargissant l'emprise spatiale, notre étude couvre ainsi une large gamme d'échelles, allant de la taille des pixels (échelle kilométrique) à l'étendue du bassin (1300 × 1400 km<sup>2</sup>), ce qui fournit une approche nouvelle à la caractérisation de DisPATCh.** De plus, les estimateurs statistiques présentés en section 2.3.2 (spectres, fonctions de structure et moments statistiques) ne peuvent rendre compte, de manière significative, des propriétés multi-échelles des données étudiées que si leur taille est suffisante (nombre de points minimum par régression linéaire). En raison de sa faible résolution spatiale, il serait alors inapproprié de procéder à une analyse multi-échelle des produits SMOS sur le bassin versant du Murrumbidgee (les images seraient composées de moins de 5 × 5 pixels).

Le bassin du Murray Darling est situé dans le Sud-Est de l'Australie et comprend plus de vingt bassins versants, dont celui du Murrumbidgee dans sa partie Sud (fig.3.10). Le climat y est subtropical dans le Nord-Est (précipitations annuelles moyennes jusqu'à 1500 mm), semi-aride dans l'Ouest (précipitations annuelles moyennes inférieures à 300 mm) et principalement tempéré dans le Sud (chutes de neige au cours de l'hiver sur les sommets de la chaîne de montagnes "Great Dividing Range"). En ce qui concerne l'occupation du sol, l'Ouest est constitué de vastes plaines sablonneuses composées essentiellement d'arbustes. Du Sud au Nord-Est s'étend la chaîne de la Great Dividing Range pouvant atteindre 2 300 m d'altitude. Les surfaces agricoles et de pâturages sont réparties sur l'ensemble du bassin, mais la plupart des zones irriguées sont situées au Sud (tel que dans la région du Murrumbidgee).

### 3.2.6 Prétraitements réalisés sur les produits satellites

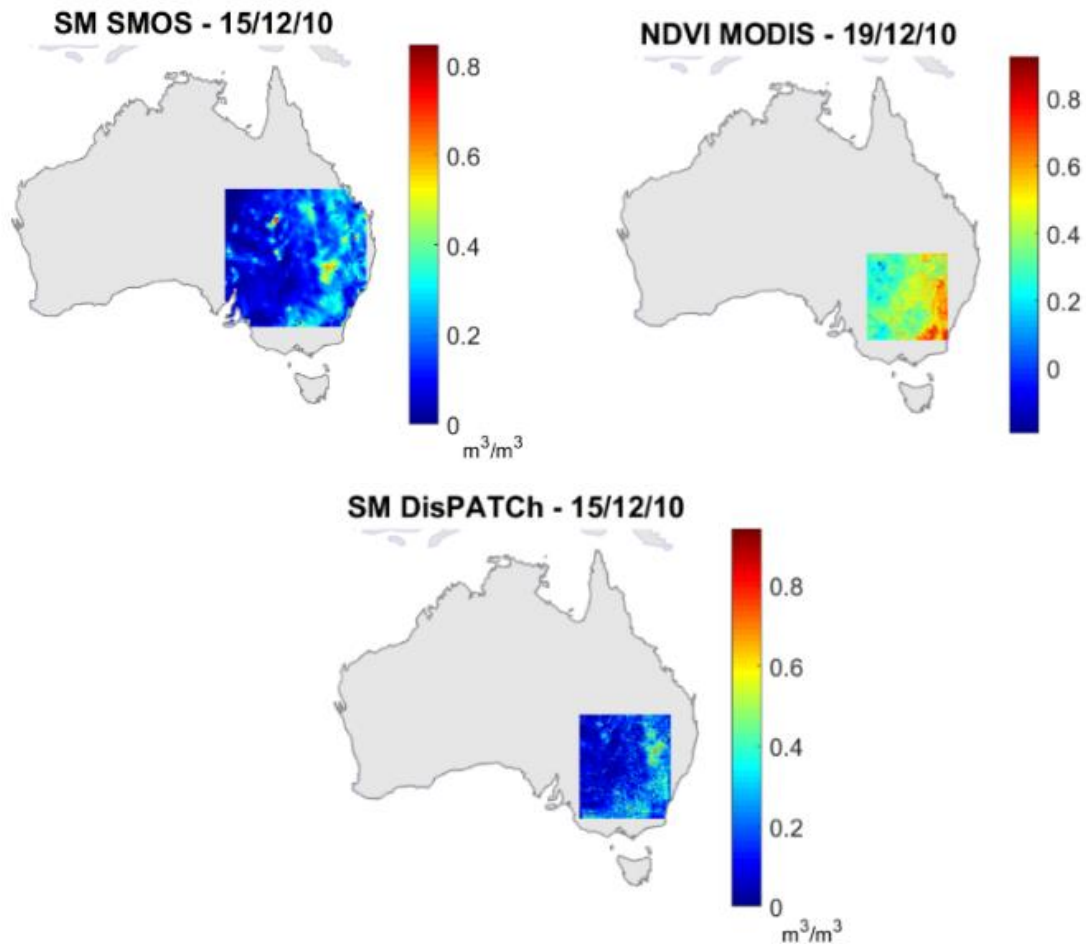
Avant de réaliser l'analyse multi-échelle, nous avons appliqué quelques prétraitements aux différents produits satellites intervenant dans DisPATCh. Nous avons suivi la méthodologie décrite en section 2.3.3, qui consiste à **prendre en compte les données manquantes (NaN) et à sélectionner des sous-images de taille  $2^n \times 2^n$  pixels.**

Pour ce qui est des données manquantes, celles-ci sont relativement importantes au sein des produits que nous analysons dans cette étude. Dans le cas des produits SMOS, ces derniers peuvent être affectés par des émissions non-autorisées qui provoquent des

interférences radiofréquences (RFI pour Radio Frequency Interference). Les produits SMOS que nous utilisons dans cette étude ont été préalablement filtrés par le CATDS de manière à éliminer les pixels avec plus de 10% de RFI (Kerr et al., 2013; Oliva et al., 2012). Pour ce qui est des produits MODIS, les pixels correspondant à des nuages sont également supprimés pour éviter l'impact de l'atmosphère sur les données désagrégées. Ainsi, les données manquantes présentes dans les produits de sortie de DisPATCh sont principalement causées par l'accumulation de données manquantes provenant des produits d'entrée. Néanmoins, grâce à la méthode combinatoire des 24 produits désagrégés implémentée dans le C4DIS (section 3.2.3), la probabilité d'obtenir des NaN dans le produit final moyenné d'humidité du sol est alors réduite.

Pour compléter ces données manquantes, nous avons appliqué une interpolation bilinéaire aux produits satellites. Pour minimiser l'impact des données interpolées sur l'analyse multifractale, nous avons rejeté les images ayant plus de 40% de NaN. De plus, afin de traiter séparément les NaN correspondant aux surfaces continentales de ceux correspondant aux zones non continentales (c'est-à-dire les océans), nous avons remplacé les NaN "hors continent" par des zéros. Cependant, certaines études ont montré qu'une proportion significative de zéros dans les données pouvait biaiser les paramètres multifractals estimés (De Montera et al., 2009; Verrier et al., 2010, 2011). Ainsi, nous avons fait attention à sélectionner des images pour lesquelles la surface au sol contenait un minimum de pixel "hors continent" (moins de 10%).

La figure 3.11 présente des exemples de sous-images de taille  $2^n \times 2^n$  sélectionnées pour les produits d'humidité SMOS (nommés *SM SMOS*), *NDVI MODIS* et d'humidité désagrégée DisPATCh (*SM DisPATCh*). Leur taille respective est  $64 \times 64$ ,  $1024 \times 1024$  et  $1024 \times 1024$  pixels (pour des raisons de lisibilité, lors du prétraitement, tous les produits MODIS ont été projetés de coordonnées sinusoïdales à orthogonales; Sohrabinia, 2012). Compte tenu de l'espacement de grille différent entre les produits, les sous-images sélectionnées pour les données SMOS couvrent l'ensemble du Murray Darling ( $1600 \times 1600 \text{ km}^2$ ), alors que les sous-images sélectionnées pour les produits *SM DisPATCh* et MODIS sont plus petites (environ  $1000 \times 1000 \text{ km}^2$ ). Il est important de noter que, même si elles ont une résolution spatiale similaire et un même nombre de pixels, les images *SM DisPATCh* et *NDVI/LST MODIS* ne correspondent pas exactement à la même surface au sol. Ceci est dû à un espacement de grille légèrement différent entre les deux produits, 1 km pour *SM DisPATCh* et 0.93 km pour les données MODIS (Didan et al., 2015; Wan, 2006). Par souci de simplicité, nous considérerons par la suite que les produits *SM DisPATCh* et MODIS présentent un même espacement de grille d'environ 1 km.



**Figure 3.11 : Sous-images sélectionnées pour chaque produit satellite sur le bassin du Murray Darling.**

Le tableau 3.3 résume les principales caractéristiques de nos produits satellites prétraités. Deux observations importantes doivent être soulignées. Premièrement, malgré leur répétitivité temporelle journalière, peu d'images *SM DisPATCh* et *LST MODIS* sont conservées pendant toute la période allant de juin à décembre: seulement 12 images pour *SM DisPATCh* et environ 70 images pour *LST MODIS*. Cela est directement lié au nombre important de données manquantes qui est en moyenne de 30% dans ces deux types de produits. Par conséquent, les données manquantes dans les produits d'humidité désagrégée semblent être principalement générées par celles des produits LST, probablement à cause de la présence de nuages dans les données. Ensuite, un autre point concerne les différentes surfaces au sol des produits prétraités. Comme elles ne se chevauchent pas complètement, les sous-images *SM SMOS* et *SM DisPATCh* peuvent capturer différentes dynamiques de l'humidité du sol. Ainsi, dans les produits SMOS, les événements extrêmes se produisant dans le nord du Murray Darling sont bien observés, alors qu'ils peuvent ne pas être pris en compte dans les données d'humidité désagrégée. Néanmoins, nous nous sommes assurés que tous les produits avaient en commun la plus grande surface au sol, en nous concentrant sur les régions irriguées situées dans la partie centre-sud du bassin (telles que le Murrumbidgee).

	Revisit (day)	Effective resolution (km)	Grid spacing (km)	Surface area (km <sup>2</sup> )	Number of images (with NaN% < 40%)	Average NaN rate (%)
SM DISPATCH	1	1	1	1024 x 1024	12	32
SM SMOS	1	40	25	1600 x 1600	203	3
LST Aqua-MODIS	1	1	≈ 1	950 x 950	60	28
LST Terra-MODIS	1	1	≈ 1	950 x 950	82	26
NDVI Terra- MODIS	16	1	≈ 1	950 x 950	13	10

**Tableau 3.3 : Caractéristiques principales des produits satellites analysés dans cette étude. Sont également précisés la surface au sol, le nombre d’images conservées et le taux moyen de données manquantes (sans les zones hors continent).**

Dans cette partie, nous venons de présenter le fonctionnement général du processeur C4DIS, permettant de fournir des produits SMOS d’humidité du sol désagrégés à la résolution kilométrique. L’algorithme DisPATCh sur lequel se base ce processeur est composé de plusieurs étapes de traitements. Celles-ci ont été détaillées et décrites, ainsi que les différentes équations correspondantes. Nous avons pu voir que la partie Sud-Est de l’Australie était une zone d’étude adaptée pour l’analyse de la variabilité spatiale de l’humidité du sol. Les nombreuses missions terrain, aéroportées et spatiales menées dans le Murray Darling, montre que ce bassin est une région propice à l’évaluation multi-échelle des produits DisPATCh.


### 3.3 Résultats

Cette partie est consacrée aux résultats obtenus après analyse multi-échelle des produits d’entrée et de sortie de l’algorithme DisPATCh. Tout d’abord, nous présenterons les résultats relatifs à l’analyse spectrale ainsi qu’aux fonctions de structure. Puis, nous terminerons par l’analyse des moments statistiques.

#### 3.3.1 Spectres de puissance : mise en évidence de deux régimes d’échelle pour l’humidité désagrégée

La figure 3.12 représente les spectres de puissance moyens estimés sur toute la période d’étude (juin-décembre 2010) des différents produits impliqués dans DisPATCh. Ici, il s’agit de spectres estimés à partir de la moyenne des spectres individuels obtenus au cours de la période. Pour rappel, chaque spectre de puissance est tracé en coordonnées log-log, avec l’axe des abscisses converti en échelle spatiale  $l$  ( $= L/k$ ) et exprimé en kilomètres.





**Figure 3.12 : Spectres de puissance moyens estimés à partir des produits d'entrée et de sortie de l'algorithme DisPATCh, pour la période Juin-Décembre 2010.**

Pour ce qui est des produits SMOS et MODIS, les spectres moyens semblent présenter des propriétés d'invariance d'échelle (ou comportement fractal) sur toute la gamme d'échelles étudiée. Ceci est observé par une évolution linéaire de  $\log(E(k))$  (Eq.2.5), avec des coefficients de détermination  $R^2$  supérieurs à 0.9 pour chaque spectre (voir tableau 3.4 pour le détail des gammes d'échelles retenues et des pentes spectrales obtenues). Rappelons que le coefficient  $R^2$  est utilisé comme mesure de la qualité de la loi d'échelle, estimé à partir de la régression linéaire entre  $\log(E(k))$  et  $\log(l)$ .

Dans le cas des produits d'humidité désagrégée, nous remarquons un comportement différent du spectre de puissance. Deux gammes d'échelles distinctes semblent apparaître, avec une pente qui s'accroît pour les échelles inférieures à la dizaine de kilomètres. Nous avons appliqué à ce spectre l'algorithme de segmentation de [D'Errico \(2017\)](#) (cf. section 2.3.3) qui a confirmé la présence d'une rupture d'échelle à  $l \approx 10$  km. Selon les différentes valeurs de pentes spectrales obtenues (tableau 3.4), une classification en trois catégories a été proposée:

- $\beta \approx 1$  : humidité SMOS, NDVI MODIS et humidité désagrégée DisPATCh ( $l > 10$  km)  
Pour ces trois produits, nous obtenons une pente des spectres qui est proche de un. Ainsi, selon l'équation 2.18, cela nous permet d'avoir une première information sur le caractère approximativement conservatif de ces produits ( $H \approx 0$ ). De plus, ces valeurs sont assez similaires à celles estimées dans la littérature: [Lovejoy et al. \(2008b\)](#) ont trouvé  $\beta = 1.2$

à la fois pour des indices de végétation et d'humidité du sol estimés à partir de produits MODIS (Guadalajara, centre de l'Espagne, juillet 2006). Des études antérieures sur la topographie, en particulier sur des surfaces volcaniques (Laferrière et Gaonac'h, 1999), ont montré des résultats comparables avec un degré d'intégration fractionnaire assez faible. Étant donné que la topographie peut influencer sur la distribution spatiale de l'humidité du sol et de la végétation (Kim et Barros, 2002b), il n'est pas surprenant d'observer un comportement d'échelle similaire entre ces variables.

- $1 < \beta < 2$  : *Température de surface MODIS*

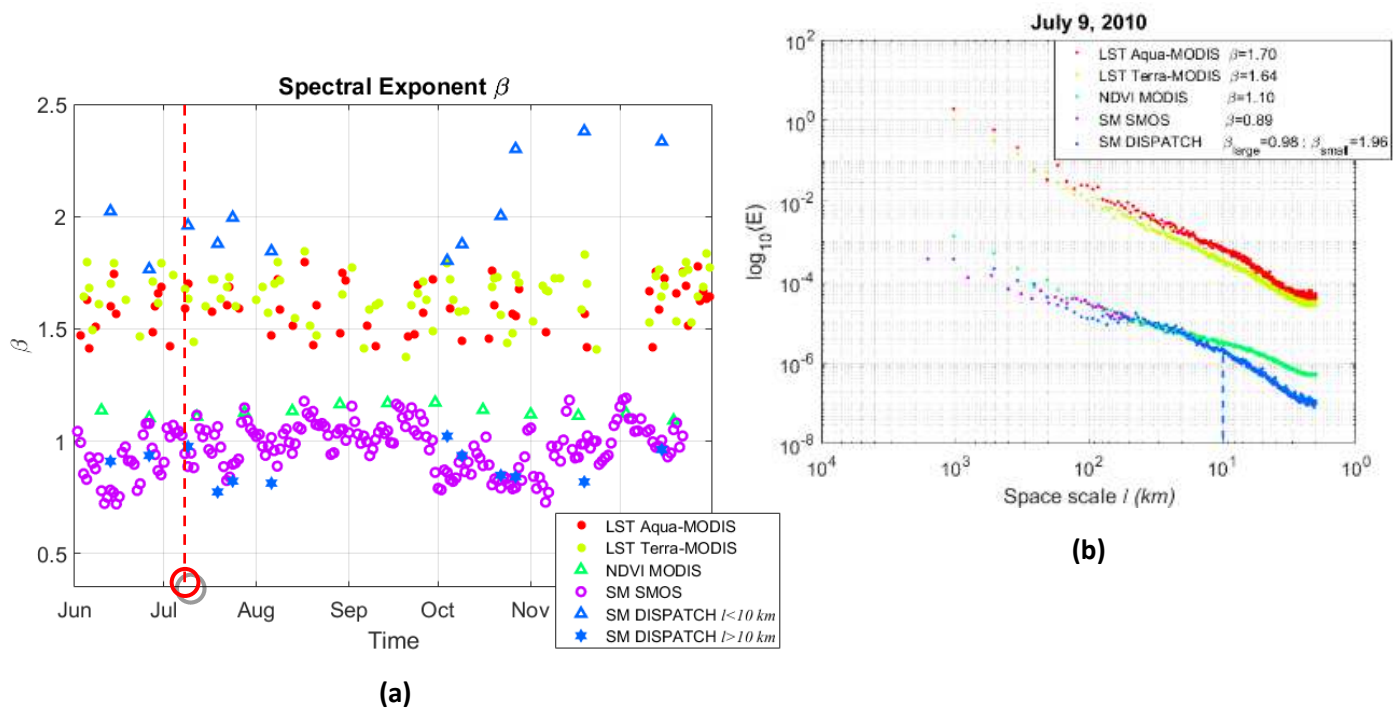
Pour les deux satellites Aqua et Terra, les spectres LST présentent ici des valeurs d'exposant spectral supérieures à 1. Dans ce cas, la température de surface semble correspondre à un champ non-conservatif ( $H > 0$ ). Ces pentes spectrales sont comparables à celles obtenues dans la littérature pour des champs de précipitation (Lovejoy et Schertzer, 2008), montrant les connexions possibles entre la distribution spatiale de la température de surface et celle de la pluie, et ainsi avec la dynamique atmosphérique sous-jacente (turbulence ; Schmitt et al., 1993).

- $\beta > 2$  : *Humidité désagrégée DisPATCH ( $l < 10 \text{ km}$ )*

Sur les fines échelles, le spectre d'humidité désagrégée présente une pente relativement importante, reflétant un degré d'intégration fractionnaire élevé ( $H > 0.5$ ). À notre connaissance, une telle valeur d'exposant spectral n'a jamais été observée dans des études antérieures sur les champs d'humidité. Cependant, des comportements d'échelle comparables ont été observés sur des séries temporelles d'humidité du sol, révélant des pentes spectrales supérieures à 2 (Katul et al., 2007).

**Nous constatons à la vue des spectres moyens que l'humidité désagrégée DisPATCH suit la même loi d'échelle que l'humidité SMOS pour des échelles supérieures à 10 km, mais que cette loi semble changer pour des échelles inférieures à la dizaine de kilomètres.** Un commentaire peut également être fait sur les spectres de puissance LST et leurs régressions linéaires: bien que les coefficients  $R^2$  présentent de bonnes valeurs sur toute la gamme d'échelles ( $> 0.9$ ), une rupture d'échelle semble présente à peu près à la même échelle spatiale que celle trouvée pour le spectre DisPATCH ( $l \approx 10 \text{ km}$ ). Cette rupture semble moins prononcée, mais elle pourrait être liée à celle de DisPATCH. Ce point sera abordé en section 3.4.2.

Ce comportement en deux gammes d'échelles peut également être observé à chaque date de la période d'étude, avec des coefficients  $R^2$  supérieurs à 0.9 sur presque toutes les images et sur les deux gammes. En figure 3.13.a, nous pouvons observer les séries temporelles des paramètres  $\beta$  estimés pour tous les produits et chaque date disponible, c'est-à-dire issus des spectres calculés *pour chaque image*. De juin à décembre, les exposants spectraux de l'humidité désagrégée présentent une différence significative entre les deux gammes d'échelle (cf. symboles bleus sur la figure 3.13.a). A titre d'exemple, les spectres estimés à partir des images acquises le 9 juillet (fig.3.13.b) sont similaires aux spectres moyens présentés ci-dessus (fig.3.12). En particulier, la même rupture d'échelle est observée pour l'humidité désagrégée à une dizaine de kilomètres. Une autre remarque concerne l'amplitude de la rupture d'échelle selon les saisons. La figure 3.13.a montre que, pour le produit *SM DisPATCH*, la différence entre les paramètres  $\beta$  des fines et larges échelles (triangles bleus et étoiles bleues) est plus importante au cours des trois derniers mois de la période. À fine échelle, la pente spectrale subit un changement radical en passant d'environ 1.9 (juin-juillet-août-sept) à 2.3 (oct-nov-déc, c'est-à-dire printemps et début d'été en Australie). Ainsi, **l'amplitude de la rupture d'échelle observée pour l'humidité désagrégée pourrait être liée aux conditions saisonnières de la zone d'étude**. Ceci sera discuté en section 3.4.1.



**Figure 3.13 : Séries temporelles des exposants spectraux sur la période Juin-Décembre 2010 (a) et spectres de puissance obtenus le 9 juillet 2010 (b).  $\beta_{large}$  et  $\beta_{small}$  font référence aux pentes spectrales de l'humidité désagrégée estimées respectivement pour les échelles  $l > 10$  km et  $l < 10$  km.**

	Grid spacing (km)	Scale range (km)	$\beta$	$R^2_\beta$	$\alpha$	$C_1$	$R^2_{K(q)}$	H	$R^2_H$
SM DISPATCH	1	[1 – 10]	2.01	0.97	1.59	0.09	0.97	0.45	0.99
		[10 – 1024]	0.89	0.92	1.64	0.03	0.96	0.15	0.98
SM SMOS	25	[25 – 1600]	0.97	0.94	1.46	0.16	0.99	0.29	0.98
LST Aqua-MODIS	$\approx 1$	$\approx [1 – 1024]$	1.60	0.98	1.7	0.03	0.96	0.26	0.98
LST Terra-MODIS	$\approx 1$	$\approx [1 – 1024]$	1.65	0.99	1.91	0.04	0.95	0.31	0.99
NDVI Terra-MODIS	$\approx 1$	$\approx [1 – 1024]$	1.13	0.98	1.74	0.03	0.96	0.15	0.99

**Tableau 3.4 : Paramètres multi-échelles issus de l'analyse multifractale des produits intervenant dans l'algorithme DisPATCh, pour la période Juin-Décembre 2010. Les valeurs de  $\beta$ ,  $\alpha$ ,  $C_1$  et H ont été obtenues à partir des régressions linéaires appliquées sur les estimateurs statistiques moyens. En revanche, les coefficients de détermination  $R^2$  présentés ici correspondent à la moyenne de l'ensemble des coefficients obtenus pour chaque date. Notons que  $R^2_{K(q)}$  correspond à la moyenne des coefficients obtenus pour chaque courbe de moments. De même, H est obtenu à partir de la moyenne des paramètres  $H_x$  et  $H_y$ , ainsi que  $R^2_H$  à partir de  $R^2_{H_x}$  et  $R^2_{H_y}$ .**


### 3.3.2 Fonctions de structure : confirment le degré d'intégration de l'humidité désagrégée et des données auxiliaires

Pour chacun des produits étudiés, la figure 3.14 représente les fonctions de structure moyennes estimées à partir de la méthode des différences (cf. section 2.3.2.2) sur l'ensemble de la période d'étude. Dans un premier temps, nous remarquons que les fonctions de chaque axe X et Y de l'image (courbes de même couleur) ont des allures comparables pour un même produit. Cela signifie que les données étudiées présentent un comportement globalement isotrope si l'on considère l'ensemble de la période d'étude. Ainsi, nous nous sommes permis de présenter en tableau 3.4 une seule valeur de H correspondant à la moyenne des paramètres  $H_x$  et  $H_y$ . De plus, nous constatons que ces fonctions de structure présentent toutes une évolution croissante des fluctuations avec l'échelle spatiale. En effet, d'après le tableau 3.4, chaque produit présente un degré d'intégration fractionnaire positif, de valeur plus ou moins importante.

Pour tous les produits sauf les données d'humidité SMOS, les valeurs de paramètre H estimées sont en adéquation avec les pentes spectrales obtenues précédemment. Dans le cas des humidités désagrégées, nous retrouvons bien une rupture d'échelle vers la dizaine de kilomètres ( $l \approx 7 \text{ km}$ , cf. gammes d'échelles en Annexe D) ainsi que des valeurs de H proches de 0 pour  $l > 10 \text{ km}$  et très élevées pour  $l < 10 \text{ km}$  ( $H \approx 0.5$ ). Cela confirme bien le caractère plutôt conservatif des produits SM DisPATCh aux grandes échelles, et en revanche non-conservatif aux fines échelles. De plus, ce comportement en deux gammes d'échelles de l'humidité désagrégée s'observe également à partir des séries temporelles des paramètres  $H_x$

et  $H_y$  présentées en Annexe E. Dans le cas des produits de température LST, les fonctions de structure moyennes présentent bien un degré d'intégration fractionnaire positif ( $H \approx 0.3$ ), correspondant à la valeur théorique  $H = 1/3$  de la turbulence couramment obtenue dans la littérature. Pour ce qui est des produits de végétation NDVI, les fonctions de structure confirment effectivement la faible valeur du paramètre  $H$  et ainsi le caractère plutôt conservatif de ces données.

En ce qui concerne les produits SMOS, le comportement observé pour les fonctions de structure ne correspond pas à celui proposé par l'analyse spectrale. Nous obtenons ici un paramètre  $H$  égal à 0.3, alors que les valeurs de  $\beta \approx 1$  laissent supposer un degré d'intégration fractionnaire nul. Cette différence peut être due à la gamme d'échelles choisie pour estimer  $H$ . En effet, dans le cas des fonctions de structure il est assez courant d'observer une chute des fluctuations  $\Delta R$  lorsque l'on se rapproche de l'échelle minimale. Dans notre cas, cela s'observe sur nos données SMOS ainsi que sur les données MODIS. Pour limiter l'impact de cet artefact numérique sur  $H$ , nous avons réduit les gammes d'échelle des données MODIS en ne prenant pas en compte les premiers points de la courbe (voir le détail des gammes d'échelles retenues en Annexe D). Or, dans le cas de SMOS, nous n'avons rejeté que le premier point de la courbe (échelle maximale) à cause du nombre déjà réduit de points sur lesquels réaliser la régression linéaire – lié à la petite taille des sous-images SMOS ( $64 \times 64$  pixels). Cela pourrait ainsi contribuer à accentuer la pente de la courbe et ainsi à surestimer le paramètre  $H$ .



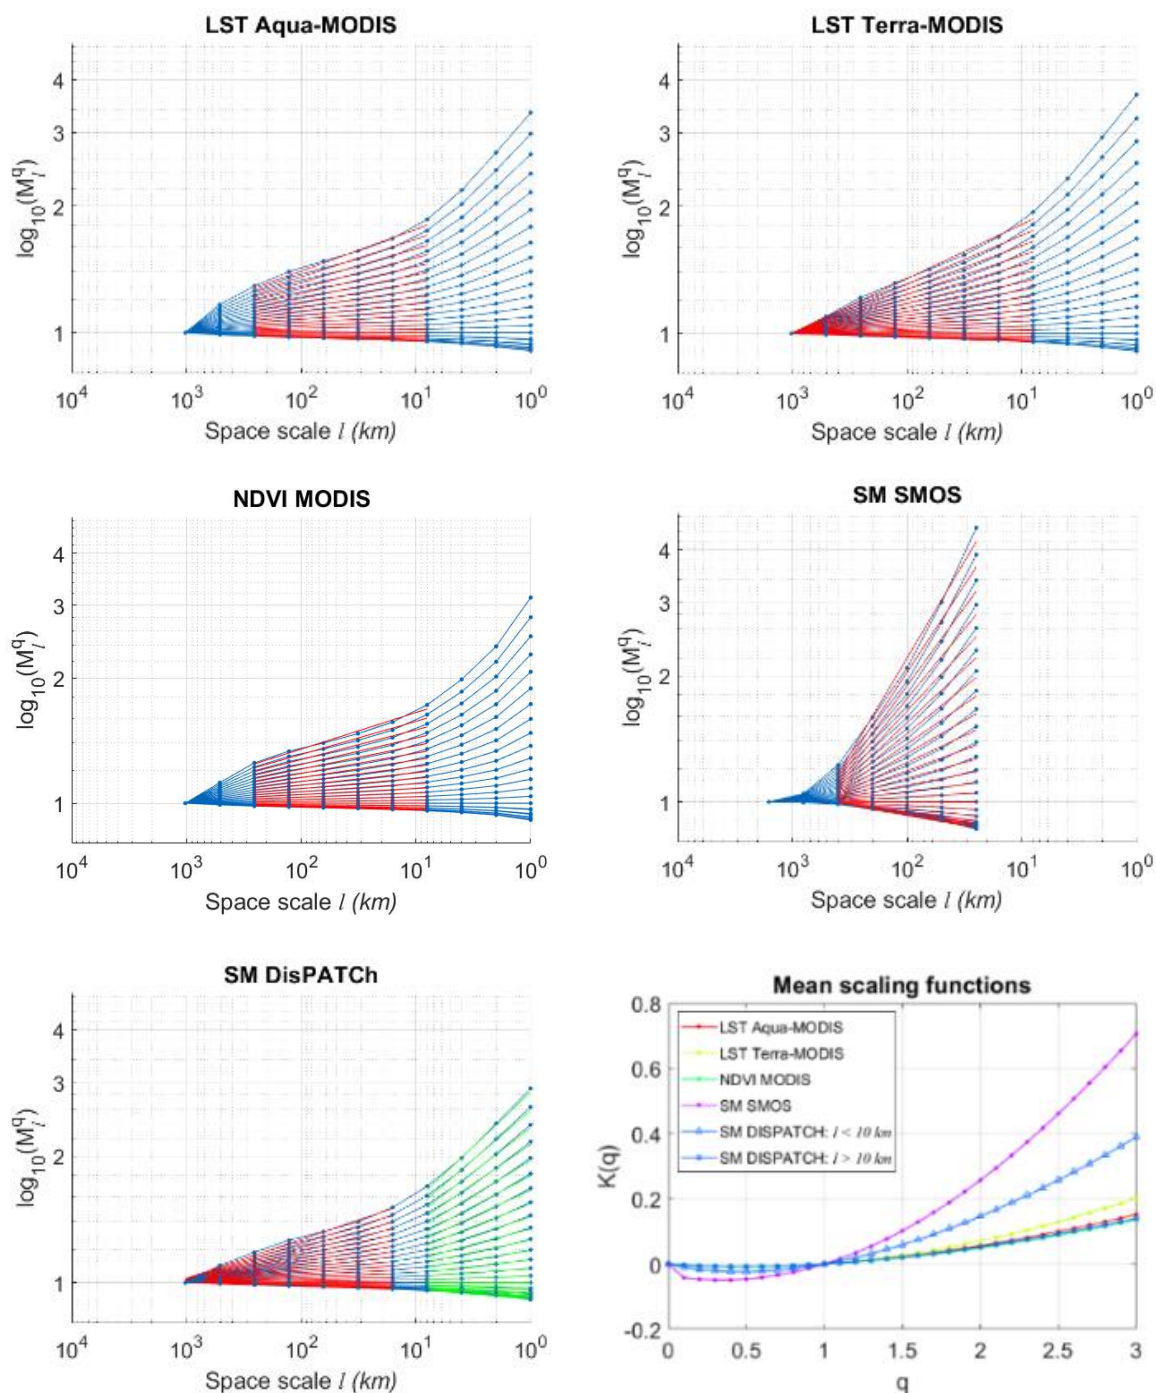
**Figure 3.14 : Fonctions de structures moyennes des produits DisPATCH estimées selon la méthode des différences, pour la période Juin-Décembre 2010.**

### 3.3.3 Moments statistiques : application du modèle des Multifractales Universelles

En figure 3.15, nous observons les moments statistiques moyens estimés pour des ordres  $q$  compris entre 0 et 3 selon la méthode décrite en section 2.3.2.3. Pour chaque produit, les gammes d'échelles sont identifiées par les droites de régressions linéaires tracées sur les graphes (également rappelées en Annexe D). La loi d'échelle décrite par l'équation 2.9 est vérifiée sur ces gammes, se traduisant par une évolution linéaire de  $\log(M_l^q)$  pour tous les ordres de moments. **Ce comportement signifie qu'un modèle multifractal est bien adapté sur les gammes correspondantes.**

Dans le cas des produits de végétation et de température MODIS, nous observons un comportement multifractal pour les échelles supérieures à 8 km. Sur ces échelles, nous avons appliqué une régression linéaire sur chaque courbe de moments (droites en rouge, fig.3.15). Ainsi, nous avons pu en déduire les fonctions d'échelle  $K(q)$  (courbes en rouge, jaune et vert) et les paramètres universels correspondants (équation 2.11). Pour la végétation, nous obtenons les valeurs de paramètres  $\alpha = 1.74$  et  $C_1 = 0.03$  (tableau 3.4). Ces dernières sont comparables à celles estimées par [Lovejoy et al. \(2008b\)](#) à partir de produits NDVI MODIS similaires ( $\alpha = 2$  et  $C_1 = 0.06$ ). Pour les températures de surface Aqua, nous avons obtenu les mêmes valeurs de paramètres que pour la végétation ( $\alpha = 1.7$  et  $C_1 = 0.03$ ), ce qui est lié à la forte similarité des fonctions  $K(q)$  de ces produits pour tous les ordres  $q$ . Des paramètres légèrement différents sont trouvés pour les produits Terra ( $\alpha = 1.91$  et  $C_1 = 0.04$ ). Cette différence pourrait être due aux temps d'acquisition différents entre les deux satellites : 10h30 pour Terra et 13h30 pour Aqua. Cela pourrait alors avoir un effet sur le comportement multi-échelle de la température de surface. Une autre raison à cette différence pourrait être la gamme d'échelles qui est plus étendue pour Terra: un comportement multifractal est observé pour des échelles allant de 8 km à 1024 km, contre 8 km à 300 km dans le cas des produits Aqua et NDVI. Quoi qu'il en soit, ces résultats confirment (NDVI) et révèlent (LST, pas encore étudié à ce jour) les propriétés multifractales de nos produits MODIS. Dans les deux cas, ils se caractérisent par un degré élevé de multifractalité ( $\alpha$  est proche de 2, valeur correspondant au cas log-normal) et par une faible dispersion du champ ( $C_1 < 0.1$ ). Pour terminer sur ces produits MODIS, nous pouvons également remarquer que la borne minimale de la gamme d'échelles (8 km) est proche de la rupture observée pour l'humidité DisPATCH (11 km, voir commentaires ci-dessous). Ainsi, il semblerait que l'analyse multifractale confirme le possible lien entre le comportement multi-échelle des produits MODIS et celui en deux gammes des données DisPATCH (section 3.4.2).





**Figure 3.15 : Moments statistiques moyens et fonctions d'échelle estimés à partir des produits DisPATCH, pour la période Juin-Décembre 2010. Chaque fonction d'échelle est obtenue à partir des régressions linéaires des moments sur les gammes d'échelles correspondantes (deux gammes pour DisPATCH et une gamme pour les autres produits).**

Les produits SMOS présentent également un bon comportement multifractal: des régressions linéaires de bonne qualité ( $R^2 = 0.99$ , cf. tableau 3.4) ont été réalisées sur une gamme incluant la plupart des échelles d'agrégation disponibles (à l'exception des deux plus grandes échelles, 1600 km et 800 km). La fonction d'échelle a été calculée pour des échelles spatiales allant de 25 km – correspondant à l'échelle d'observation du capteur (espacement

de grille) – à 400 km (courbe violette sur le graphe  $K(q)$ , fig.3.15). Par rapport aux produits MODIS, on observe une divergence croissante entre les fonctions d'échelle des humidités SMOS et des données NDVI/LST, en particulier pour les ordres  $q$  supérieurs à 1. Ce comportement d'échelle se confirme par des paramètres universels différents à ceux des produits MODIS :  $\alpha = 1.46$  et  $C_1 = 0.16$ . À notre connaissance, aucune application du modèle MU n'a encore été réalisée sur des données satellites d'humidité du sol acquises par micro-ondes passives. Par conséquent, il est difficile de comparer ces résultats à la littérature. Cependant, bien qu'ils n'aient pas utilisé le modèle MU, [Kim and Barros \(2002b\)](#) ont étudié les propriétés d'échelle spatiale d'humidité du sol estimée à l'aide d'un radiomètre bande-L aéroporté (expérience *Southern Great Plains 1997, Etats-Unis*). En effet, ils ont observé un comportement multifractal sur une gamme d'échelles similaire (1.6 km – 250 km), ce qui est cohérent avec nos résultats. [Lovejoy et al. \(2008b\)](#) ont quant eux appliqué le modèle MU, mais à des données d'indice d'humidité du sol estimées à partir des réflectances de surface MODIS ([Lampkin et Yool, 2004](#)). Ils ont obtenu des valeurs de paramètres  $\alpha = 2$  et  $C_1 = 0.05$  pour des échelles spatiales inférieures (0.5 km – 25 km). Ces valeurs sont assez éloignées des nôtres, ce qui pourrait être expliqué par la différence des gammes d'échelles et des zones d'étude (Guadalajara, centre de l'Espagne, dans [Lovejoy et al., 2008b](#)) entre leurs travaux et les nôtres. Une autre raison pourrait être liée à la nature du signal étudié. Les indices estimés par capteurs optiques (section 4.1.1), tels que l'indice d'humidité MODIS, sont fortement sensibles à l'occupation du sol telle que la végétation ([Fabre et al., 2015](#); [Haubrock et al., 2008](#)), qui impacte ainsi les propriétés d'échelle de l'humidité du sol.

Si l'on analyse maintenant les produits d'humidité désagrégée, un changement de pente est observé pour chacun des moments statistiques. Le même algorithme de segmentation a été appliqué sur toutes les courbes de moment, révélant une rupture d'échelle à une dizaine de kilomètres (11 km plus exactement). On peut observer ici deux régimes d'échelle multifractals, confirmant le comportement en deux gammes détecté sur les spectres de puissance. En considérant les larges échelles ( $l > 10 \text{ km}$ , droites de régression en rouge sur la figure 3.15), les paramètres estimés sont :  $\alpha = 1.64$  et  $C_1 = 0.03$ . Ces valeurs sont proches des celles trouvées pour les produits MODIS (NDVI et LST), correspondant à un degré élevé de multifractalité et une faible dispersion du champ. Pour les plus fines échelles ( $l < 10 \text{ km}$ , droites en vert), le degré de multifractalité est presque inchangé ( $\alpha = 1.59$ ) par rapport à la gamme des larges échelles. En revanche, nous constatons que la valeur du paramètre de dispersion est augmentée ( $C_1 = 0.09$ ), correspondant à trois fois la valeur obtenue sur les larges échelles. Ainsi, **la différence de comportement multifractal entre les deux régimes semble être principalement liée à la dispersion de l'humidité à travers les échelles.** Si nous nous référons à l'analyse multifractale de l'indice d'humidité MODIS faite par [Lovejoy et al. \(2008b\)](#), nos estimations sont cohérentes pour ce qui est du paramètre  $\alpha$  (sur les deux gammes d'échelles) et du paramètre  $C_1$  (à grande échelle). [Lovejoy et al. \(2008b\)](#)

n'ayant pas remarqué de rupture d'échelle, il est donc difficile de commenter notre estimation de  $C_1$  pour  $l < 10 \text{ km}$ . Néanmoins, [Kim and Barros \(2002b\)](#) ont observé une rupture d'échelle similaire (à peu près à la même échelle de 10 km) sur des données micro-ondes passives d'humidité du sol. En effet, ils ont détecté deux régimes d'échelle à partir des tracés de la variance, des spectres et des moments. Ainsi, **le comportement en deux gammes des produits d'humidité désagrégée DisPATCH semble cohérent avec la rupture d'échelle identifiée en premier lieu par [Kim et Barros \(2002b\)](#).**

En conclusion de cette partie résultat, nous pouvons dire que l'analyse multifractale des produits d'entrée de DisPATCH a révélé la présence de propriétés d'invariance d'échelle sur les gammes d'échelles considérées. En effet, les produits NDVI/LST MODIS et le produit d'humidité SMOS sont caractérisés par une évolution en loi puissance de leurs spectres, fonctions de structure et moments statistiques, reflétant le caractère fractal et multifractal des processus mesurés. Cependant, un comportement multi-échelle spécifique a été observé pour l'humidité désagrégée par DisPATCH. A partir des différents estimateurs statistiques, deux régimes d'échelle ont été obtenus, avec une échelle de transition observée à une dizaine de kilomètres. A grande échelle ( $l > 10 \text{ km}$ ), l'analyse spectrale a révélé un comportement d'échelle similaire entre l'humidité désagrégée et l'humidité d'origine mesurée par satellite. Sur les échelles plus fines ( $l < 10 \text{ km}$ ), un comportement différent a été observé, avec une pente plus accentuée du spectre de puissance. Une rupture d'échelle similaire a été détectée sur les fonctions de structure et moments statistiques, montrant que **les propriétés à la fois fractales et multifractales de l'humidité désagrégée sont caractérisées par ce comportement en deux gammes d'échelles**. Plusieurs facteurs peuvent être à l'origine de ce phénomène, lesquels seront proposés et discutés dans la section suivante.

## 3.4 Discussion


Afin d'expliquer le comportement en deux gammes d'échelles de l'humidité du sol DisPATCH, nous allons proposer ici deux arguments possibles : une interprétation plus physique en première sous-partie, puis une explication davantage algorithmique dans la deuxième sous-partie.

### 3.4.1 Impact des facteurs environnementaux sur les propriétés statistiques multi-échelles de l'humidité

#### 3.4.1.1 Des facteurs agissant à différentes échelle spatiales

Puisque la variabilité spatiale de l'humidité du sol est influencée par plusieurs facteurs environnementaux (Brocca et al., 2007; Crow et al., 2012), **la rupture d'échelle observée sur l'humidité désagrégée pourrait être le résultat de processus agissant à différentes échelles spatiales**. A des échelles fines ( $l < 10 \text{ km}$ ), la structure spatiale de l'humidité du sol est régie par des phénomènes d'infiltration ou de ruissellement, qui sont principalement liés aux propriétés du sol (texture, structure) (Hawley et al., 1983; Famiglietti et al., 1998). En revanche, à plus grande échelle ( $l > 10 \text{ km}$ ), la variabilité de l'humidité est davantage affectée par des processus d'évapotranspiration (Mohanty et Skaggs, 2001) ou par les précipitations (Jackson et al., 1999).

Cette rupture d'échelle fut également observée par Kim and Barros (2002b) en estimant les spectres de puissance (fig.3.16) et les moments statistiques de données d'humidité du sol acquises à partir du radiomètre bande-L aéroporté ESTAR (*Southern Great Plains 1997, Etats-Unis*). Notons que ces données d'humidité ont été obtenues à une résolution nominale de 1 km à partir du modèle  $T - \omega$  (Jackson et Schmugge, 1991), qui prend en compte les estimations du contenu en eau de la végétation VWC (Vegetation Water Content) basées sur des mesures de NDVI. Kim and Barros (2002b) ont observé que **la relation entre la structure spatiale de l'humidité du sol et les caractéristiques du paysage était fortement modulée par le niveau moyen d'humidité du sol**. En effet, ils ont appliqué une analyse par décompositions en fonctions orthogonales empiriques EOF (Empirical Orthogonal Functions) entre l'humidité et des données auxiliaires, à savoir la topographie, la composition du sol et des mesures de VWC. Ainsi, ils ont pu mettre en évidence une forte corrélation entre l'humidité du sol et la topographie durant les événements pluvieux, alors qu'une corrélation plus élevée avec la végétation (teneur en eau) a été observée pendant les périodes plus sèches (principalement régies par les processus d'évapotranspiration).




**Figure 3.16 : Résultats obtenus par Kim and Barros (2002b) : spectres de puissance estimés à partir de deux images d'humidité du sol acquises pour un jour humide et un jour sec, durant la mission SGP-97. Nous pouvons observer une rupture de pente vers la dizaine de kilomètres, ainsi qu'une augmentation de cette rupture en conditions plus sèches (courbe pleine).**

### 3.4.1.2 Une rupture en lien avec les propriétés d'échelle de la pluie

Ces résultats sont intéressants car d'autres études ont également observé une rupture d'échelle similaire dans le cas de produits de précipitation obtenus par radar à une résolution de 1 km (Sud-Est de la France, Gires et al., 2011). En effet, une échelle de transition a été détectée sur les spectres (fig.3.17.b) et moments statistiques à une vingtaine de kilomètres (non loin de notre rupture d'échelle de 10 km). Cependant, certaines limitations relatives à l'acquisition de données radars doivent être prises en compte vis-à-vis de ces résultats. En effet, les contraintes dues aux traitements algorithmiques (changement de coordonnées polaires à cartésiennes, impact des données manquantes, intégration temporelle...) et à la physique (atténuation par la pluie, etc.) peuvent impacter les propriétés d'échelle des images radars de précipitations. De plus, la relation  $Z - R$  entre la réflectivité radar et le taux de pluie (Marshall et Palmer, 1948) reste quelque peu controversée, avec une paramétrisation non robuste d'un point de vue multi-échelle (Verrier et al., 2013). Ainsi, dans ce contexte, la significativité de la rupture d'échelle détectée par Gires et al. (2011) peut être remise en question. Néanmoins, ces derniers ont également analysé le comportement multifractal de précipitations simulées. Celles-ci ont été générées sur la même zone d'étude, à une résolution

de  $\sim 2$  km, à partir du modèle atmosphérique Meso-NH (Lafore et al., 1997). L'analyse a révélé la présence d'une rupture d'échelle comparable à environ 30 km (fig.3.17.a), ce qui tend à montrer que cette échelle de transition dans les données de précipitation n'est pas un artefact. **Étant donné que les précipitations sont un forçage important de l'humidité, on peut penser qu'une rupture sur le spectre de la pluie se répercuterait sur celui de l'humidité, et ce de manière d'autant plus significative que les précipitations sont intenses.**



**Figure 3.17 : Résultats obtenus par Gires et al. (2011) : spectres moyens des données de précipitations simulées selon le modèle Meso-NH (a) et mesurées par radar (b).**


De plus, un modèle théorique de l'humidité du sol dans le domaine temporel a été proposé par Katul et al. (2007) pour relier le comportement d'échelle des précipitations à celui de l'humidité. En effet, les exposants spectraux de ces deux variables se sont révélés être reliés sur des échelles de temps inférieures à 7 jours, à l'aide de la simple équation suivante :  $\beta_{SM} = \beta_P + 2$  (avec  $\beta_{SM}$  et  $\beta_P$  les pentes spectrales respectives des séries temporelles d'humidité et de précipitations). Bien que ces résultats aient été observés sur des acquisitions temporelles, cela aurait tendance à corroborer la **possible dépendance entre la variabilité de l'humidité du sol et celle des précipitations, même dans le domaine spatial.**

### 3.4.1.3 Les effets saisonniers sur la variabilité spatiale de l'humidité

Si l'on s'intéresse aux variations saisonnières, les spectres de puissance de l'humidité désagrégée DisPATCH semblent révéler un comportement en deux gammes d'échelles prononcé en particulier au printemps et au début de l'été (période d'octobre à décembre, fig.3.13.a). Comme les images DisPATCH correspondent à des zones principalement situées dans la partie centre-sud du bassin du Murray Darling, le climat est donc principalement tempéré. Par conséquent, les derniers mois de la période d'étude correspondent à des conditions climatiques plus sèches. Ainsi, les deux régimes d'échelle semblent encore plus




distincts lorsque le sol est davantage asséché. Pour démontrer cet effet, la moyenne spatiale de l'humidité DisPATCH ( $\mu(SM)$ ) ainsi que la différence absolue  $|\beta_{large} - \beta_{small}|$  ont été calculées pour chaque image désagrégée. Sur la figure 3.18, les anomalies normalisées de ces deux variables sont conformes à cette hypothèse (cercles bleus et triangles rouges) : un comportement en deux gammes plus prononcé semble être observé pour les jours les plus secs (oct-nov-déc). Kim and Barros (2002b) ont observé un phénomène similaire, avec des différences de comportement multi-échelle plus faibles lors d'événements pluvieux (observés à la fois sur les spectres et les moments). À certaines dates, ils ont même remarqué qu'il n'y avait aucune rupture d'échelle, correspondant à des taux d'humidité du sol très élevés. De plus, nous avons estimé la position des ruptures d'échelle sur chaque spectre de puissance au cours de la période, et en avons tracé les anomalies normalisées correspondantes (étoiles grises, fig.3.18). Bien que la rupture soit positionnée en moyenne autour des 10 km (non indiqué ici, mais la valeur moyenne sur toute la période a été estimée à  $\sim 13$  km), l'échelle de transition entre les deux régimes semble suivre une tendance décroissante au fur et à mesure que le sol s'assèche, présentant des valeurs allant de 15 km en période humide à 12 km en période sèche. Kim and Barros (2002b) ont observé une évolution comparable, montrant que **la position et l'amplitude de la rupture d'échelle dépendaient de l'état de l'humidité du sol, et ainsi des conditions hydrométéorologiques telles que la pluie, l'évapotranspiration et les processus d'infiltration.**



**Figure 3.18 : Séries temporelles sur la période Juin-Décembre 2010 des anomalies normalisées des trois variables suivantes : la moyenne spatiale de chaque produit d'humidité DisPATCH ; la différence absolue entre les exposants spectraux  $\beta_{large}$  et  $\beta_{small}$  (estimés respectivement pour  $l > 10$  km et  $l < 10$  km) ; la position des ruptures d'échelle estimée par segmentation pour chaque spectre. La ligne en pointillés différencie les deux régimes : plutôt humide de juin à septembre et plus sec d'octobre à décembre.**

Pour aller plus loin sur la relation entre les saisons et le comportement d'échelle, Kim and Barros (2002b) ont observé que les propriétés multifractales de l'humidité du sol étaient presque toujours présentes pour des échelles inférieures à 10 km, quel que soit le niveau de sécheresse du sol. Cependant, à des échelles plus larges, supérieures à 10 km, ils ont pu constater que ces propriétés devenaient monofractales, en particulier en conditions sèches. Pour des échelles relativement larges (entre 25 km et 400 km) nous avons détecté un phénomène similaire sur nos produits d'humidité SMOS (cercles violets, fig.3.19) : la valeur de l'indice de multifractalité  $\alpha$  se voit diminuer d'environ 1.6 (juin) à 1.3 (décembre), ce qui traduirait une décroissance modérée de la multifractalité au cours de la période d'étude. Par conséquent, **les propriétés multifractales de l'humidité pour les grandes échelles semblent effectivement liées à l'état de sécheresse du sol**. Cela contribue ainsi à fournir certaines explications complémentaires au comportement en deux gammes d'échelles de l'humidité du sol. D'autre part, si l'on considère le produit d'humidité DisPATCh, nous pouvons voir une évolution plutôt constante du paramètre  $\alpha$ , à la fois sur les fines échelles (triangles bleus) et sur les grandes échelles (étoiles bleues). Le premier cas confirme l'idée que la multifractalité n'est pas dépendante du niveau de sécheresse du sol pour les petites échelles spatiales, tandis que le second cas est en contradiction avec cette hypothèse. Ainsi, ces dernières observations doivent être considérées avec précautions pour expliquer les propriétés d'échelle de l'humidité.



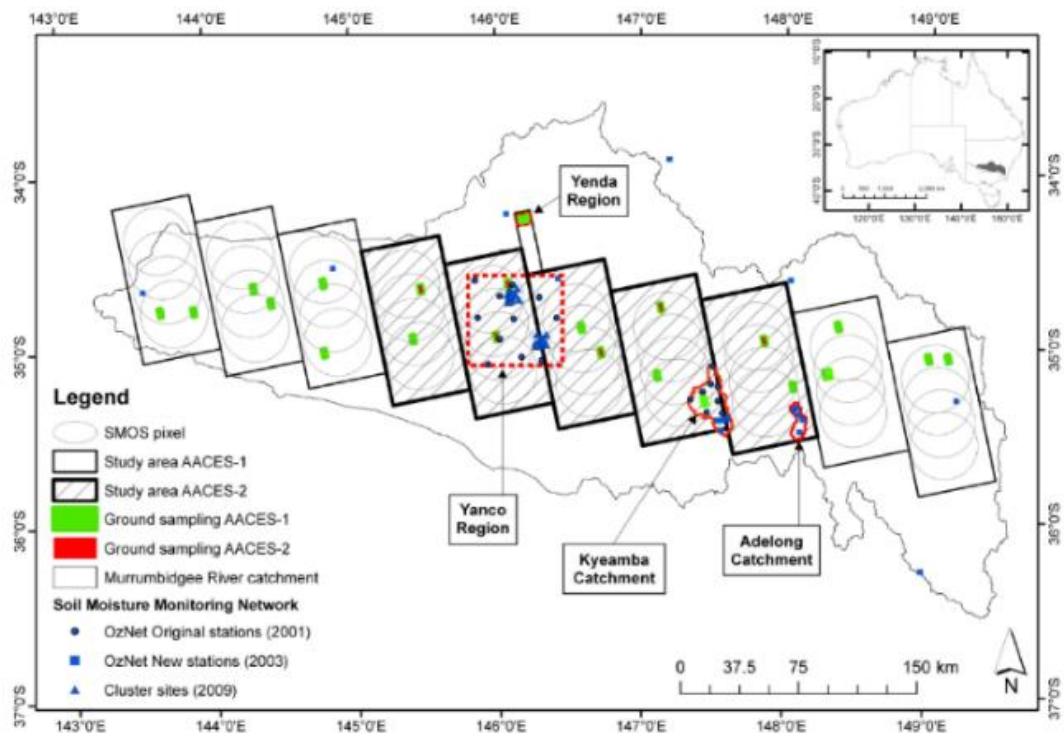
**Figure 3.19 : Séries temporelles de l'indice de multifractalité  $\alpha$  pour la période Juin-Décembre 2010.**

### 3.4.2 Effet de l'algorithme de désagrégation sur les propriétés statistiques multi-échelles de l'humidité

#### 3.4.2.1 Mise en évidence d'un seul régime d'échelle pour les températures de brillance : cas de la mission AACES-2

Des travaux relativement récents ([Mascaro et al., 2010](#); [Mascaro and Vivoni, 2012](#)), ont mis en évidence les propriétés multifractales de produits d'humidité du sol acquis par radiomètres bande-L aéroportés (*Southern Great Plains, 1997 et 1999, États-Unis*). Dans ces études, l'analyse multifractale a été réalisée au moyen du modèle Log-Poisson ([She et Levêque, 1994](#) ou cf. section 2.2.2.2) : un seul régime d'échelle a été observé sur les moments statistiques, correspondant à la gamme 0.8 km – 25.6 km. Bien que ce résultat confirme les propriétés multifractales de l'humidité pour des échelles spatiales similaires aux nôtres, il réfute l'existence de deux régimes d'échelle. **Aucune rupture d'échelle n'a été détectée à une dizaine de kilomètres.** Comme le modèle Log-Poisson est fondé sur la même théorie "universelle" que le modèle MU (cascades continues), il est quelque peu inattendu de ne pas détecter la même transition sur des produits d'humidité comparables (même technologie et même gamme d'échelles).

Pour déterminer si cette différence de résultats entre ces travaux et les nôtres peut être liée aux cas d'étude (zones ou périodes distinctes), nous avons comparé nos produits DisPATCH aux données aéroportées fine échelle acquises au cours de la mission AACES-2 ([Peischl et al., 2012](#)). Cette mission a été réalisée en septembre 2010, au cours de laquelle des vols par transect ont été effectués dans le bassin versant du Murrumbidgee. Des températures de brillance (TB) ont été acquises à partir du radiomètre bande-L PLMR (Polarimetric L-band Multibeam Radiometer) pour des polarisations H et V (directions verticale ou horizontale de réception du signal), et à une résolution spatiale de 1 km. La zone d'étude a été divisée en cinq sections de  $50 \times 100 \text{ km}^2$  (fig.3.20), correspondant chacune à un jour de vol spécifique (13, 16, 19, 21 et 22 septembre).



*Figure 3.20 : Campagnes AACES réalisées sur le bassin du Murrumbidgee en septembre 2010 : les mesures aéroportées AACES-2 correspondent aux cinq sections (rectangles en gras) situées sur la moitié centrale de la zone d'étude (d'après Peischl et al., 2012).*

Pour notre analyse, nous avons regroupé les cinq sections AACES-2 afin d'obtenir une seule image de TB, et en avons sélectionné une sous-image de  $128 \times 128 \text{ km}^2$  (zone en pointillés rouges, fig.3.21.a). Pour vérifier la présence de deux régimes d'échelle dans ces données, nous avons appliqué une analyse spectrale aux sous-images de TB, pour les deux cas de polarisations H et V. En figure 3.21.b, nous avons comparé le spectre de puissance des TB en polarisation H (nommées ici *BT AACES*) à ceux des différents produits intervenant dans DisPATCH sur une période équivalente. Pour cela, nous avons calculé la moyenne des spectres estimés pour chaque produit disponible entre les 13 et 22 septembre. Etant donné qu'aucun produit d'humidité désagrégée n'a été retenu sur cette période (trop de données manquantes), nous avons sélectionné le produit disponible le plus proche, correspondant au 4 octobre. D'après la figure 3.21.b, **un seul comportement d'échelle est observé pour le spectre de *BT AACES* sur l'ensemble de la gamme d'échelles (1 km – 128 km), et avec une pente spectrale comparable à celle du spectre SMOS ( $\beta \approx 1$ )**. Notons que le spectre des TB en polarisation V n'a pas été tracé ici, mais il révèle un comportement similaire que nous présentons en Annexe F.

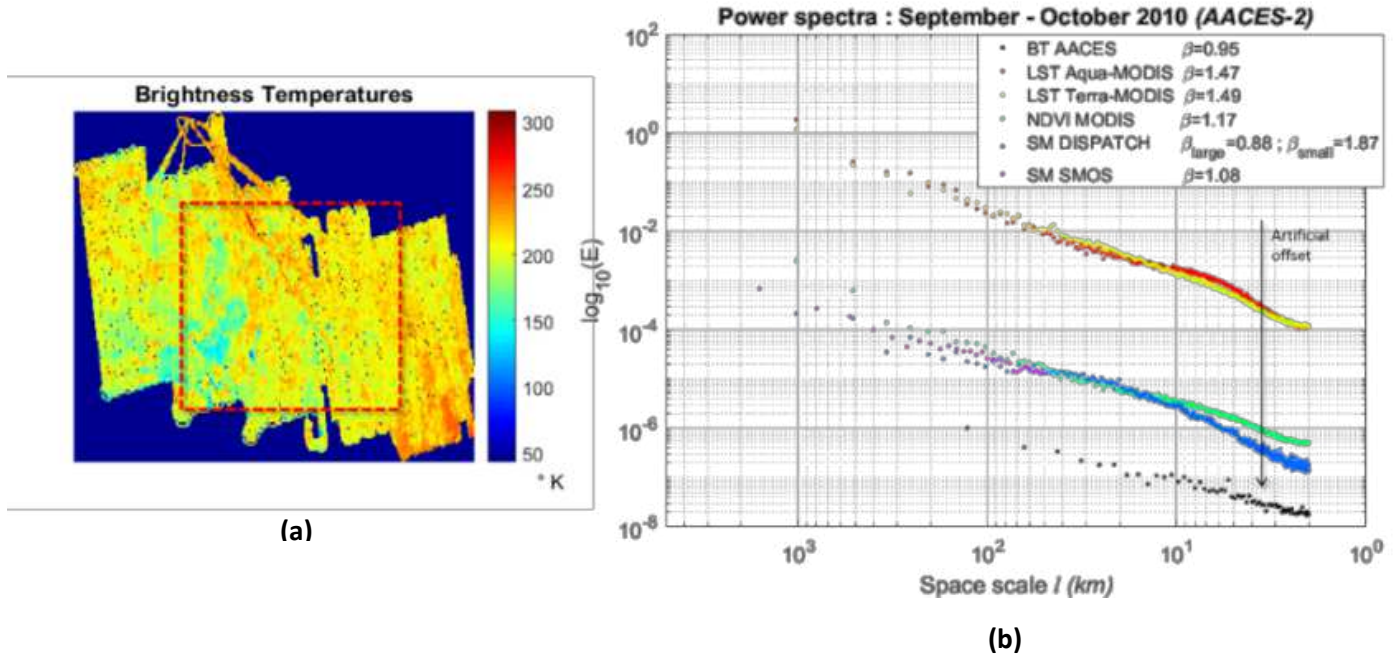



Figure 3.21 : (a) Températures de brillances acquises durant la campagne AACES-2. Les pointillés rouges définissent la sous-image extraite pour notre étude. (b) Spectres de puissance des TB ainsi que des différents produits impliqués dans DisPATCh, obtenus sur la période Septembre-Octobre 2010. Par souci de visualisation et de comparaison, le spectre des TB a été décalé sur la partie basse du graphe (flèche noire).

### 3.4.2.2 Suivi des propriétés multi-échelles au sein de l'algorithme DisPATCh : implémentation d'une version simplifiée de la méthode

Ainsi, pour des zones et des périodes similaires, nous avons pu observer des comportements d'échelle différents entre les températures de brillance AACES et les humidités désagrégées DisPATCh. **Cela semblerait appuyer l'idée que la rupture d'échelle observée à 10 km pourrait être provoquée par le modèle DisPATCh et, en particulier, par la manière dont les propriétés multi-échelles de chaque produit sont mélangées dans l'algorithme.** Pour vérifier cette hypothèse, j'ai implémenté *une version simplifiée du processeur C4DIS* afin d'étudier le comportement multi-échelle des différentes variables combinées et générées au sein de l'algorithme. Le but étant notamment de pouvoir analyser les produits intermédiaires (SEE, température du sol) qui ne sont pas fournis par l'implémentation opérationnelle de DisPATCh. Pour ce faire, j'ai suivi la méthodologie proposée par [Molero et al. \(2016\)](#) consistant à considérer les étapes décrites à la section 3.2.4 : (1) extraction de la composante "sol" de la température de surface à partir des produits *LST/NDVI MODIS* (Eq.3.2-3) (2) estimation de l'efficacité évaporative du sol  $SEE_{HR}$  (Eq.3.4) et (3) désagrégation des produits d'humidité SMOS d'après les variables  $SEE_{HR}$  et  $SM_p$  (Eq.3.6-7).




Selon cette méthode, j'ai appliqué cet algorithme sur des produits SMOS et MODIS acquis le 19 novembre 2010. Une zone d'environ  $700 \times 700 \text{ km}^2$  fut sélectionnée à l'intérieur des sous-images habituellement utilisées (section 3.2.6) de manière à avoir le moins de données manquantes possibles, et ainsi à minimiser l'impact de l'interpolation sur les produits étudiés. La figure 3.22 présente le produit d'humidité désagrégée  $SM_{HR}$  que nous avons obtenu. Nous constatons que celui-ci est comparable au produit fourni par le C4DIS acquis le même jour et dans la même "sous-zone" ( $SM_{C4DIS}$ ), ce qui peut s'observer sur les deux images correspondantes qui semblent présenter des caractéristiques pratiquement identiques. En effet, notre produit  $SM_{HR}$  a été obtenu suivant la même méthodologie combinatoire implémentée dans le C4DIS décrite en section 3.2.3 consistant à réaliser la moyenne de plusieurs images désagrégées issues de plusieurs combinaisons SMOS/LST. Cependant, notons que le produit  $SM_{HR}$  présenté en figure 3.22 n'est obtenu qu'à partir d'une seule image SMOS en entrée de l'algorithme (d'espacement de grille  $\sim 25 \text{ km}$ ), au lieu des quatre images sous-échantillonnées ( $\sim 40 \text{ km}$ ), nous limitant donc à six combinaisons SMOS/LST (et non 24). En effet, nous avons pu tester les deux approches (une image SMOS d'une part et quatre images SMOS sous-échantillonnées d'autre part), mais aucune différence significative n'a été observée entre les produits finaux et entre leurs spectres de puissance (Annexe G). Ainsi, par simplicité de traitement, nous avons choisi de nous restreindre au cas d'une image SMOS.



**Figure 3.22 : Comparaison des produits désagrégés d'humidité du sol obtenus après application de notre version simplifiée de DisPATCh ( $SM_{HR}$ ) et à partir du processeur C4DIS ( $SM_{C4DIS}$ ), pour le 19 novembre 2010.**



La figure 3.23 ci-dessous présente les spectres de puissance estimés à partir des produits d'entrée de DisPATCH ( $LST$ ,  $NDVI$ ), des produits intermédiaires ( $T_{S,HR}$ ,  $SEE_{HR}$ ) et du produit de sortie ( $SM_{HR}$ ). À titre de comparaison, le spectre du produit d'humidité  $SM$  C4DIS a également été tracé. **Nous avons appliqué l'algorithme de segmentation à chaque spectre de puissance et avons pu observer deux ruptures communes aux différents produits.** La moyenne géométrique des différentes positions estimées pour ces deux ruptures a révélé une première rupture près des dix kilomètres ( $l = 9 \text{ km}$ ) et une seconde à une trentaine de kilomètres ( $l = 33 \text{ km}$ ). Pour évaluer le lien entre le comportement multi-échelle de chaque produit, les exposants spectraux ont été estimés sur les deux gammes d'échelles suivantes: de 33 km à 9 km (*larges échelles*) et de 9 km à 1 km (*finies échelles*). En comparant notre produit  $SM_{HR}$  avec le produit  $SM$  C4DIS (tableau 3.5), nous constatons des comportements d'échelle très similaires pour les larges échelles ( $\beta_{large} \approx 1.3$ ). Sur les fines échelles, nous obtenons des valeurs plus élevées :  $\beta_{small} \approx 2$  pour  $SM_{HR}$  et  $\beta_{small} \approx 2.86$  pour  $SM$  C4DIS. Ces différentes pentes spectrales sur la gamme fine échelle pourraient être liées au fait que n'avons pas pris en compte certaines étapes de filtrage dans notre version de l'algorithme, qui sont effectivement codées dans le processeur C4DIS : corrections des effets de la topographie, filtrage de données LST de faible qualité, etc. (Molero et al. , 2016). Ces différences expliquent pourquoi les images représentées sur la figure 3.22 ne sont pas parfaitement identiques.



**Figure 3.23 : Spectres de puissance des produits d'entrée, intermédiaires et de sortie obtenus à partir de notre implémentation de l'algorithme DisPATCH, pour le 4 Novembre 2010. Le spectre du produit final C4DIS est également tracé ici. Par souci de visualisation et de comparaison, nous avons modifié la position verticale (axe-Y) des différents spectres de puissance.**

Scale range (km)	[33 - 9]		[9 - 1]		$\Delta\beta$
Spectral exponent	$\beta_{large}$	$R^2_{\beta}$	$\beta_{small}$	$R^2_{\beta}$	
LST - Aqua	1.08	0.97	1.91	0.98	0.83
LST - Terra	1.39	0.97	2.01	0.98	0.62
NDVI	0.93	0.94	1.22	0.98	0.29
Ts - Aqua	0.90	0.95	1.55	0.98	0.65
Ts - Terra	1.33	0.98	1.79	0.98	0.46
SEE - Aqua	0.88	0.96	1.61	0.98	0.73
SEE - Terra	1.25	0.97	1.83	0.98	0.58
$SM_{HR}$	1.22	0.96	2.08	0.97	0.86
SM C4DIS	1.29	0.96	2.86	0.98	1.57

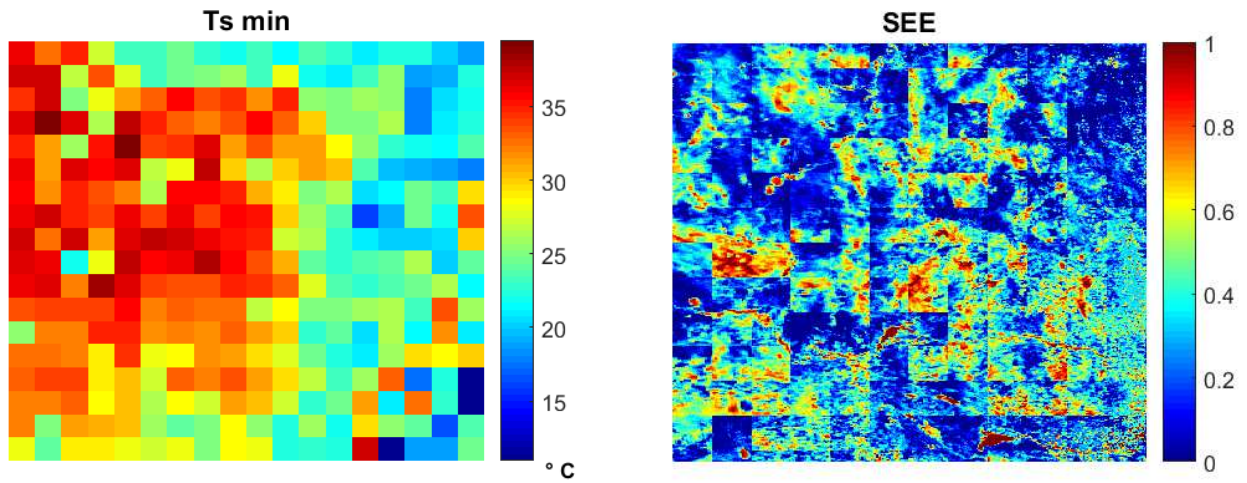
*Tableau 3.5 : Paramètres  $\beta$  obtenus à partir de l'analyse spectrale des produits combinés et générés dans DisPATCH, pour le 19 novembre 2010 (fig.3.23). Les coefficients  $R^2$  ont été estimés d'après les régressions linéaires réalisées sur les gammes d'échelles correspondantes.  $\Delta\beta = |\beta_{large} - \beta_{small}|$  est utilisé comme indicateur de l'amplitude de la rupture, avec large et small faisant référence respectivement aux gammes [33 – 9] km et [9 – 1] km.*

En dépit de ces différences entre les spectres de  $SM_{HR}$  et  $SM_{C4DIS}$ , la rupture d'échelle reste tout de même présente, comme cela semble être le cas pour les autres produits de l'algorithme. Pour mettre en évidence cela, nous avons calculé et utilisé la différence absolue  $\Delta\beta = |\beta_{large} - \beta_{small}|$  comme indicateur de l'amplitude de la rupture (tableau 3.5). Des valeurs supérieures à 0.6 ont été obtenues pour les produits LST (Aqua et Terra),  $T_s$  (Aqua) et SEE (Aqua). **Ainsi, ces résultats semblent montrer que les données de température de surface mesurées par MODIS seraient la cause de la rupture d'échelle observée à une dizaine de kilomètres pour les humidités désagrégées.** Cette rupture se propagerait alors dans l'algorithme DisPATCH via l'estimation des produits  $T_s$  et SEE. **Une explication possible à la présence de cette rupture dans les produits LST pourrait être liée à la méthode d'acquisition et de traitement de ces données.** En effet, nous verrons dans le chapitre suivant que le système d'acquisition des capteurs optiques peut affecter les propriétés statistiques multi-échelles des signaux mesurés, en particulier pour les hautes fréquences spatiales, contribuant ainsi à modifier la pente spectrale près de la résolution du capteur. Nous invitons le lecteur à se référer à la section 4.4.1 pour plus de détails sur ce phénomène.

Nous remarquons néanmoins que cet effet semble plus important sur les données LST issues du satellite Aqua ( $\Delta\beta = 0.83$ ) que celles provenant de Terra ( $\Delta\beta = 0.62$ ). De même, des différences similaires peuvent être observées entre les spectres moyens de LST Terra et LST Aqua correspondant à l'ensemble de la période d'étude (fig.3.12, section 3.3.1). Ainsi, ces

observations laissent penser que l'amplitude de la rupture d'échelle serait en lien avec le cycle diurne de la température de surface. Etant donné que les températures de surface mesurées depuis Aqua sont acquises aux heures les plus chaudes de la journée (13:30), il pourrait y avoir une corrélation entre l'amplitude de la rupture d'échelle et le niveau de température de surface. Cependant, cette hypothèse est en contradiction avec l'explication liée au système d'acquisition par capteur optique, qui suggère à l'inverse une rupture indépendante du signal mesuré.

Si nous nous intéressons à la rupture d'échelle détectée à  $\sim 30$  km, **une possibilité serait que cette transition de régime ne soit pas liée aux propriétés des données MODIS mais éventuellement à la combinaison de produits définis sur des grilles différentes.** En effet, l'algorithme DisPATCH combine et génère des produits dont l'espacement de grille est soit celui des données MODIS ( $\sim 1$  km) soit celui des données SMOS ( $\sim 25$  km). Par exemple, l'estimation de la SEE (Eq.3.4) consiste à combiner les termes  $T_{s,max}$  et  $T_{s,min}$  – définis sur la grille SMOS (une valeur de  $T_{s,max}$ ,  $T_{s,min}$  pour chaque pixel SMOS) – avec le produit  $T_s$  défini quant à lui sur la grille MODIS. Sur la figure 3.24, une "trace" des pixels SMOS est alors observable sur l'image de SEE estimée. **Ce phénomène est dû à la stratégie de ré-échantillonnage des données SMOS et aux termes  $T_{s,max}$ ,  $T_{s,min}$  définis sur la grille SMOS.** Cette empreinte systématique est visible dans le domaine réel mais peut également avoir un impact dans le domaine de Fourier. En effet, les transitions nettes situées aux limites des pixels SMOS peuvent créer des convolutions parasites par des fonctions de type sinus cardinal pouvant affecter le spectre. Sur le produit désagrégé d'humidité, cela peut générer une transition "imparfaite" entre la partie du spectre liée à l'humidité SMOS ( $l > 25$  km) et la partie liée aux produits MODIS ( $l < 25$  km). En observant le comportement du spectre de SEE pour les échelles supérieures à trente kilomètres (figure 3.23), nous constatons une pente spectrale plus faible ( $\beta \approx 0.5$ ) comparée à celle obtenue sur des échelles plus fines ( $\beta \approx 1$ ). Cela pourrait être relié au sur-échantillonnage des données SMOS, qui générerait des harmoniques aux fines échelles et par conséquent réduirait la variabilité aux échelles plus larges. **Ainsi, cet effet affecterait à la fois les larges et les fines échelles spatiales, contribuant d'une certaine façon à accentuer la chute spectrale détectée à fine échelle sur le produit final d'humidité désagrégée.**



*Figure 3.24 : Images correspondant aux produits  $T_{s,min}$  et  $SEE_{HR}$  obtenus d'après notre implémentation de DisPATCH pour le 19 novembre 2010.*

Dans cette partie discussion, nous venons de proposer deux explications au comportement en deux gammes d'échelles de l'humidité désagrégée DisPATCH. Une interprétation plus physique indiquerait que la rupture observée serait le reflet de processus hydrométéorologiques non-linéaires tels que les précipitations, l'évapotranspiration ou l'infiltration agissant à différentes échelles spatiales et modulés par les propriétés du sol et la végétation. Une deuxième explication serait plus algorithmique et directement liée aux traitements des différents produits utilisés et générés au sein de l'algorithme DisPATCH. En particulier, cette rupture proviendrait en partie des produits d'entrée LST MODIS et en partie par les artefacts de traitement liés à la combinaison de plusieurs produits définis par différents espacements de grille.

### 3.5 Conclusion

Depuis la fin du siècle dernier, plusieurs études ont été menées pour étudier les propriétés multi-échelles de l'humidité du sol. Pour cela les chercheurs ont utilisé des technologies très diversifiées permettant de mesurer et d'analyser la structure spatiale de l'humidité, telles que les micro-ondes passives acquises par avion ou satellite, les mesures de télédétection radar ainsi que l'estimation d'indices par capteurs optiques. De plus, différentes méthodes d'analyse multi-échelle ont été appliquées, telles que les spectres de puissance, les moments statistiques, les dimensions fractales, et même différentes sortes de modèles de cascades (Log-Poisson, Multifractales Universelles, voire dans certains cas sans paramétrisation explicite de la fonction  $K(q)$ ). Dans cette étude, nous avons analysé le comportement multi-échelle de produits satellites d'humidité du sol pour des échelles spatiales allant de l'échelle kilométrique à l'échelle continentale. Le modèle des Multifractales Universelles a été appliqué pour la première fois aux données d'humidité SMOS, donnant accès à une variabilité large échelle de l'humidité du sol sur le paysage australien. Des propriétés fractales et multifractales ont été observées, ce qui a confirmé et complété certains résultats existants de la littérature.

L'aspect original de cette étude porte selon nous sur l'analyse multi-échelle des produits de sortie d'un algorithme de désagrégation, en l'occurrence de l'algorithme de désagrégation DisPATCH (Merlin et al., 2008a; Molero et al., 2016). Cet algorithme déterministe améliore la résolution spatiale des produits d'humidité du sol SMOS de 40 km à 1 km. Pour faire cela, il combine les humidités basse résolution acquises par SMOS aux données optiques/thermiques haute résolution ( $\sim 1$  km) mesurées par MODIS. Bien que plusieurs études de validation de la méthode de désagrégation aient été réalisées à ce jour (Malbêteau et al., 2016; Merlin et al., 2012, 2013, 2015; Molero et al., 2016), aucune n'a exploré en détail son comportement statistique sur un continuum d'échelles spatiales. Dans ce contexte, nous avons appliqué une analyse fractale et multifractale aux différents produits impliqués dans l'algorithme DisPATCH, incluant les produits désagrégés (et originaux) d'humidité du sol et les données auxiliaires MODIS qui sont les indices de végétation (NDVI) et les températures de surface (LST).

Les produits d'entrée de DisPATCH ont révélé des lois d'échelle relativement bien vérifiées sur les gammes d'échelles étudiées. En effet, les données de NDVI, LST et humidité d'origine SMOS ont présenté une évolution en loi puissance de leurs spectres, fonctions de structure et moments statistiques, reflétant le caractère fractal et multifractal des processus mesurés. Cependant, un comportement multi-échelle spécifique a été observé pour l'humidité désagrégée DisPATCH. A partir des différents estimateurs statistiques, deux régimes d'échelle ont été obtenus, avec une échelle de transition observée à une dizaine de kilomètres. A grande échelle ( $l > 10$  km), l'analyse spectrale a révélé un comportement

d'échelle similaire entre l'humidité désagrégée et l'humidité d'origine mesurée par satellite. Sur les échelles plus fines ( $l < 10 \text{ km}$ ), un comportement différent a été observé, avec une pente plus accentuée du spectre de puissance. Une rupture d'échelle similaire a été détectée sur les fonctions de structure et moments statistiques, montrant que les propriétés à la fois fractales et multifractales de l'humidité désagrégée sont caractérisées par ce comportement en deux gammes d'échelles.

Pour expliquer ce comportement particulier de l'humidité désagrégée, nous avons proposé deux arguments possibles. Premièrement, une interprétation plus physique indiquerait que ce comportement en deux gammes serait relié aux propriétés physiques de l'humidité du sol. En effet, comme cela a été précédemment observé par [Kim and Barros \(2002b\)](#), une telle rupture d'échelle serait le reflet de processus hydrométéorologiques non-linéaires (pluie, infiltration, évapotranspiration) agissant à différentes échelles spatiales et modulés par le relief, la composition/structure du sol ainsi que la répartition de la végétation. La structure spatiale de l'humidité serait davantage impactée par les phénomènes d'infiltration ou d'écoulement à l'échelle de la parcelle, tandis qu'elle serait majoritairement contrôlée par l'évapotranspiration ou les précipitations aux échelles régionales et continentales. De plus, une transition d'échelle plus marquée a été observée pour les jours les plus secs (début d'été), ce qui soutiendrait le lien entre l'humidité du sol et des agents externes de forçage tels que les précipitations.

Une deuxième explication serait plus algorithmique et directement liée aux traitements des différents produits utilisés et générés au sein de l'algorithme. Le modèle sur lequel se base DisPATCH produirait des données d'humidité dont les statistiques ne sont pas correctement réparties à travers les échelles. Cela aurait lieu à deux niveaux dans l'algorithme. Tout d'abord, certaines propriétés des produits MODIS (telles que des transitions de comportement d'échelle) seraient retrouvées dans le produit final DisPATCH. En effet, nous avons pu détecter pour les données LST une chute de leur spectre à une échelle également située vers la dizaine de kilomètres. Bien qu'elle soit moins prononcée que pour l'humidité désagrégée, cette rupture d'échelle serait introduite par les produits LST puis amplifiée par le modèle de désagrégation. De plus, notre analyse complémentaire de températures de brillance haute résolution acquises en bande L sur la même zone et la même période a révélé la présence d'un seul régime d'échelle. Ainsi, cela suggère que ce comportement d'échelle inattendu dans les produits MODIS serait causé par la technologie spécifique aux capteurs optiques/thermiques. Ensuite, un autre impact de l'algorithme sur les propriétés multi-échelles de l'humidité du sol serait en lien avec les artefacts de traitements engendrés par la combinaison de plusieurs produits définis par différents espacements de grille. Bien que cette combinaison soit nécessaire pour permettre la conservation de l'humidité entre les produits d'entrée et de sortie, d'un point de vue purement "traitement du signal" cela peut créer une empreinte systématique sur l'image finale (limite des pixels SMOS visible sur le produit

désagrégé) et ainsi affecter le spectre de puissance (convolutions par des fonctions sinus cardinales).

**A ce stade, il est difficile de déterminer lequel des facteurs physique ou algorithmique serait à l'origine de ce comportement en deux gammes d'échelles. Néanmoins, une hypothèse plausible serait que les deux facteurs pourraient affecter de manière conjointe les propriétés multi-échelles de l'humidité désagrégée. En effet, nous pensons qu'une rupture située à une échelle proche de la résolution de l'humidité SMOS pourrait être initialement produite par les artefacts de traitements, et que cette même rupture serait plus ou moins amplifiée à travers l'algorithme selon les conditions saisonnières, entraînant le déplacement de la rupture d'échelle au cours de la période vers des échelles plus fines.**

Des travaux supplémentaires doivent être entrepris pour expliquer pleinement ces résultats, en particulier pour déterminer dans quelle mesure chacun des deux facteurs a une incidence sur le comportement d'échelle de l'humidité DisPATCh. En premier lieu, les données auxiliaires pourraient être comparées à nos produits. En effet, une analyse EOF (ou comparable) effectuée sur les données DisPATCh et des données auxiliaires, telles que la topographie, la teneur en eau de la végétation ou le contenu du sol, fournirait des informations pertinentes sur le lien entre la variabilité spatiale de ces produits et faciliterait ainsi l'interprétation de nos résultats. De plus, il serait intéressant de vérifier si des produits de précipitations acquis sur la même période (Juin-Décembre 2010) et sur la même zone (bassin du Murray Darling) sont caractérisés par une transition d'échelle similaire, située à des échelles spatiales équivalentes. Cependant, notons qu'une telle comparaison peut s'avérer complexe à interpréter car, à notre connaissance, aucun modèle théorique n'a encore été proposé pour relier les propriétés d'échelle spatiales de l'humidité et celles de la pluie (comme cela a déjà été fait auparavant dans le domaine temporel, cf. [Katul et al., 2007](#)). De la même manière, la comparaison entre les humidités DisPATCh et les températures de brillance (TB) n'est pas si triviale, en raison des opérations relativement complexes qui sont nécessaires à l'inversion de l'humidité d'après les mesures de TB. Pour illustrer cela, [Mascaro and Vivoni \(2012\)](#) ont observé un comportement monofractal à partir de données de TB, tandis que des propriétés multifractales ont été observées à partir des humidités inversées correspondantes. Ainsi, les propriétés d'échelle des TB pourraient être affectées au cours du processus d'inversion, ce qui expliquerait pourquoi l'unique régime d'échelle que nous avons observé sur ces données n'implique pas un unique régime sur les humidités. Par conséquent, une analyse multifractale de réels produits d'humidité du sol à haute résolution permettrait de clarifier cette idée et de contribuer à valider la variabilité spatiale des produits DisPATCh.

Dans l'hypothèse d'une rupture d'échelle induite par le modèle, des travaux en cours visent à quantifier l'effet des produits MODIS et la trace des pixels SMOS à différentes dates



et dans des conditions opérationnelles de fonctionnement (analyse des produits utilisés et générés au sein du processeur C4DIS). De plus, des applications de DisPATCh utilisant des données auxiliaires Landsat-7/8 au lieu des produits MODIS ont été réalisées ([Merlin et al., 2013](#); [Ojha et al., 2019](#)), permettant une désagrégation à des échelles infra-kilométriques (100 m). Dans la mesure où Landsat-7/8 délivrent des données optiques/thermiques avec une résolution supérieure à celle de MODIS, il pourrait être intéressant de vérifier si à la fois les produits Landsat-7/8 et les produits désagrégés sont caractérisés par une rupture d'échelle similaire, mais décalée vers des échelles plus fines que l'échelle de 10 km observée sur MODIS. Par conséquent, les résultats obtenus pourraient aider à quantifier l'impact réel des données auxiliaires optiques/thermiques sur les propriétés multi-échelles de l'humidité du sol DisPATCh. Sur un plan plus opérationnel, si cet impact est confirmé, les résultats obtenus pourraient aider à définir une échelle spécifique en dessous de laquelle la variabilité générée par le modèle de désagrégation risque de ne pas être aussi fiable qu'elle devrait l'être. En ce qui concerne l'impact des pixels SMOS sur le produit désagrégé, une solution pour atténuer cet effet d'empreinte pourrait être de filtrer les transitions nettes aux limites des pixels SMOS. Récemment, [Ojha et al. \(2019\)](#) ont proposé une méthode basée sur une fenêtre à moyenne mobile permettant de réduire les artefacts basse résolution présents sur des images désagrégées d'humidité du sol SMAP. Ainsi, cette technique a permis d'augmenter l'efficacité de l'algorithme DisPATCh en améliorant la corrélation spatio-temporelle de l'humidité désagrégée (ici à 100 m) avec des mesures terrain. Toutefois, ce type de correction doit être fait avec précaution, car de tels filtres peuvent atténuer excessivement la variance fine échelle du produit désagrégé.

Sous un angle peut-être plus théorique, une autre manière d'analyser le comportement de l'humidité DisPATCh pourrait consister à se concentrer sur son comportement dynamique à différentes échelles d'agrégation. En effet, l'un des principaux problèmes lors de la désagrégation d'un comportement dynamique provient du fait que le comportement dynamique d'un signal agrégé ne peut être approché par la même structure d'équation déterministe que lorsque la zone agrégée est en synchronisation de phase ([Mangiarotti et al., 2016](#)). Ainsi, l'applicabilité de méthodes de désagrégation déterministes telles que DisPATCh peut ne pas être aussi évidente pour certaines échelles spatiales, ce qui pourrait engendrer des difficultés et peut-être contribuer à expliquer les irrégularités d'échelle observées dans cette étude.

Enfin, une possibilité pourrait être de comparer la variabilité de l'humidité du sol produite par DisPATCh avec celle générée par les méthodes de désagrégation stochastique fractales. Basées sur les propriétés d'échelle, ces méthodes ont l'avantage de préserver la validité de la distribution de probabilité lors d'un changement de résolution faisant passer des grandes échelles vers les fines échelles. En précipitations, plusieurs études ont appliqué ces algorithmes à des données de pluie ([Rebora et al., 2006](#); [Sharma et al., 2007](#)). Certains travaux

de recherche ont proposé des méthodes développées sur le principe des cascades multiplicatives telles que le modèle Log-Poisson (Deidda, 2000) ou le modèle des Multifractales Universelles (Gires et al., 2012), permettant entre autres de quantifier les erreurs d'incertitude et de représentativité entre mesures basse résolution et données in-situ. En ce qui concerne l'humidité du sol, certaines études se sont basées sur de telles méthodes fractales pour réaliser la désagrégation (Bindlish et Barros, 2002; Kim et Barros, 2002a; Mascaro et al., 2010). Ainsi, dans notre étude, il pourrait être intéressant d'appliquer ce type de méthode aux produits SMOS. Cela consisterait à injecter dans le modèle des Multifractales Universelles les valeurs des paramètres  $\alpha$  et  $C_1$  obtenues à partir des humidités SMOS basse résolution, puis à prolonger la cascade à des résolutions supérieures. En suivant cette procédure, le champ généré à fine échelle aura alors les mêmes propriétés multi-échelles que le champ aux échelles plus larges. Cependant, cette désagrégation étant basée sur un générateur aléatoire, un ensemble de champs possibles peut être proposé à partir d'une seule paire de paramètres  $\alpha/C_1$ . Par conséquent, ce type de méthodologie peut ne pas être suffisamment adapté dans le cas d'applications opérationnelles hydro-agricoles, en particulier pour déterminer la position des extrêmes. **Pour éviter ce problème, une combinaison des deux approches pourrait constituer un compromis intéressant entre désagrégation stochastiques par cascades multiplicatives et désagrégation déterministe basée sur les processus d'évaporation.** Par exemple, dans l'algorithme DisPATCH, une piste pourrait être de proposer un estimateur modifié de la SEE qui serait utilisé dans la désagrégation (Eq.3.7). Cet estimateur modifié serait calculé en appliquant un filtre 2D sur la SEE d'origine, ce qui reviendrait à effectuer une intégration fractionnaire d'ordre  $\Delta H = H_{recherché} - H_{non-filtré}$ , avec  $H_{recherché}$  et  $H_{non-filtré}$  les paramètres mesurés respectivement à partir des humidités du sol SMOS (larges échelles) et de la SEE non filtrée (pour les échelles inférieures à 10 km). **De cette manière, la pente spectrale de la SEE produite pourrait être ajustée, comme celle de l'humidité finale désagrégée.** Ainsi, les champs large échelle et fine échelle pourraient être reliés par un degré commun d'intégration fractionnaire, ce qui pourrait contribuer à limiter le comportement en deux gammes d'échelles observé sur le produit désagrégé. En pratique, cette modification ne serait pas évidente à mettre en œuvre car le filtrage devrait être correctement dimensionné afin de n'affecter que les fines échelles, comprises entre 1 et 10 km. De plus, cette correction modifiant directement la texture de l'image, elle pourrait avoir un impact sur les propriétés physiques de la SEE. Ainsi, un compromis devrait donc être fait entre propriétés "statistiques multi-échelles" ou propriétés "déterministes évaporatives".

## 4 Caractérisation de données multispectrales à haute résolution spatiale par analyse multifractale

---

Ce chapitre porte sur l'analyse multifractale de données Sentinel-2 dans la région Sud-Ouest de la France, sur l'année 2016. Cette étude a pour objectif de montrer l'intérêt de l'approche multi-échelle pour caractériser des données multispectrales à haute résolution spatiale, et pour mettre en évidence l'hétérogénéité des surfaces continentales. Dans une première partie, nous introduirons le principe de mesure des réflectances de surface et l'apport de ces dernières pour l'étude de l'hétérogénéité spatiale. Nous détaillerons également les effets de l'atmosphère sur ces réflectances et nous présenterons les méthodes de correction développées à ce jour pour atténuer cet impact et permettre un suivi temporel régulier des surfaces. Une deuxième partie sera consacrée à la présentation de la zone d'étude, des données satellites utilisées et de la chaîne de traitement atmosphérique MAJA. Ensuite, nous exposerons les résultats obtenus après analyse multifractale des produits Sentinel-2. Puis, ce chapitre se terminera par une discussion de ces résultats et une conclusion présentant quelques perspectives envisageables pour compléter ces travaux.

### 4.1 Introduction

#### 4.1.1 Apport des données multispectrales pour l'étude des surfaces continentales

##### 4.1.1.1 Réflectances de surface : principe et intérêt

Pour acquérir des informations sur les surfaces continentales, diverses techniques de télédétection sont utilisées de nos jours via les satellites opérationnels d'observation de la Terre. Nous distinguons des méthodes dites de télédétection "active" mesurant la façon dont le signal émis par le satellite est ensuite rétrodiffusé par le sol (imagerie radar). D'autres méthodes observent directement la manière dont les surfaces continentales réfléchissent les rayonnements solaires. Il s'agit de la télédétection passive. Cela est possible grâce aux capteurs optiques qui permettent d'estimer la réflectance de surface dans le domaine du visible, proche et moyen infrarouge (cf. section 2.1.1). Cette grandeur physique est intéressante pour étudier les propriétés des sols car elle varie en fonction de l'occupation du sol (sol nu, végétation, eau...), de son état (sol sec ou humide, végétation jeune ou sénescence) et dépend de la longueur d'onde dans laquelle elle a été acquise.

Pour obtenir des réflectances, plusieurs traitements doivent être réalisés sur les rayonnements électromagnétiques acquis par le capteur. Ce dernier mesure l'énergie solaire réfléchi par la Terre notée  $Q$  (exprimée en Joules) qui est liée aux propriétés de la scène observée, mais qui dépend aussi d'autres facteurs liés aux conditions d'acquisition telles que la longueur d'onde, les caractéristiques du capteur ou encore l'éclairement solaire. Il est nécessaire de s'affranchir de ces facteurs pour obtenir une information caractéristique de la surface seulement. En effet, le signal initialement mesuré par le capteur correspond à une énergie acquise pendant une certaine durée (temps d'intégration  $t_i$ ), sur une certaine unité de surface  $ds$  (celle du détecteur), pour une longueur d'onde  $\lambda$  (à ne pas confondre ici avec la notation utilisée pour la résolution en théorie fractale) et suivant un angle d'observation (angle solide  $d\Omega_s$ ). Une première étape de traitement consiste à normaliser l'énergie mesurée suivant le temps d'intégration (Tupin et al., 2014) :

$$F = \frac{Q}{t_i} \quad 4.1$$

avec  $F$  le flux (en Watts) correspondant à la puissance lumineuse acquise par le détecteur. Celle-ci est ensuite divisée par la surface du détecteur et la sensibilité spectrale  $S(\lambda)$ , correspondant à la sensibilité du capteur qui est différente en fonction des longueurs d'onde :

$$E = \frac{F}{S(\lambda) ds} \quad 4.2$$

Cette grandeur est appelée éclairement ou irradiance et s'exprime en  $\text{W.m}^{-2}.\mu\text{m}^{-1}$ . Celle-ci est divisée par l'angle solide d'observation du capteur :

$$L = \frac{E}{d\Omega_s} \quad 4.3$$

Ainsi, la grandeur physique obtenue, appelée luminance ou radiance (exprimée en  $\text{W.m}^{-2}.\text{sr}^{-1}.\mu\text{m}^{-1}$ ), ne dépend plus des caractéristiques du capteur. Une dernière étape consiste à supprimer l'effet de l'éclairement solaire  $E_s$  ( $\text{W.m}^{-2}.\text{sr}^{-1}.\mu\text{m}^{-1}$ ) qui, pour une même surface, peut induire des variations de luminance liées aux saisons (changement de la distance Terre-Soleil). En effet, la luminance  $L$  est issue de la réflexion par la Terre de l'éclairement émis par le Soleil ( $E_s$ ). Afin d'accéder à la proportion de rayonnement réfléchi par la Terre (liée aux propriétés de la surface), il est donc nécessaire de diviser la luminance par l'éclairement solaire en prenant en compte quelques contraintes géométriques liées à l'angle  $\theta_s$  entre les rayons du soleil et la surface (Tupin et al., 2014) :

$$\rho = \frac{\pi L}{E_s \cos(\theta_s)} \quad 4.4$$

Ainsi, la réflectance  $\rho$  enfin obtenue est une grandeur sans unité, ne dépendant plus de l'éclairement solaire. Cette réflectance dépend tout de même de la longueur d'onde ainsi que de l'angle zénithal  $\theta_s$  sous lequel la surface est éclairée. Le facteur  $\pi$  utilisé dans cette équation assure une réflectance maximale égale à 1 lorsque l'intégralité de l'éclairement solaire incident est réfléchi vers le ciel par la surface.


Cela nous amène donc à introduire l'intérêt de l'acquisition multispectrale pour la caractérisation et la discrimination des surfaces terrestres. Celles-ci vont réagir de manières différenciées à la lumière émise par le Soleil (éclairement solaire  $E_s$ ). En théorie de l'électromagnétisme, ce dernier est assimilé à un corps noir qui émet, selon la loi de [Planck \(1901\)](#), de l'énergie répartie sur une large gamme de longueurs d'onde allant de l'ultraviolet ( $\sim 0.1 \mu m$ ) jusqu'au moyen infrarouge ( $\sim 10 \mu m$ ) :

$$E_{\text{Corps noir}}(\lambda, T) = \frac{2hc^2}{\lambda^5} \frac{1}{e^{\frac{hc}{\lambda kT}} - 1}$$

4.5

Cette grandeur, bien qu'elle soit souvent qualifiée "d'éclairement", correspond à une luminance exprimée en  $W.m^{-2}.sr^{-1}.\mu m^{-1}$ . Elle varie en fonction de la longueur d'onde  $\lambda$  ainsi que de la température  $T$  du corps, et se définit à partir de la vitesse de la lumière  $c$  et des constantes de Planck  $h$  et de Boltzmann  $k$ .

Selon leurs propriétés (composition, structure, humidité, etc.), les surfaces terrestres vont réfléchir, absorber ou transmettre cette énergie différemment en fonction de la longueur d'onde : on parle alors de signature spectrale. La figure 4.1 présente l'évolution, pour différents types de sol, des réflectances en fonction de la longueur d'onde dans le domaine visible à proche infrarouge. Nous pouvons voir que la végétation (ici l'herbe) présente une forte variation de son spectre, allant de faibles réflectances dans le domaine du visible ( $0.4 - 0.7 \mu m$ ) à de fortes réflectances qui sont presque triplées dans le proche infrarouge ( $0.8 - 1 \mu m$ ). Cette signature particulière est en grande partie liée à la présence de chlorophylle qui absorbe différemment la lumière selon la longueur d'onde. Ce comportement de la végétation est très différent de celui de l'eau ou du béton par exemple. Bien que ce ne soit pas présenté sur la figure ci-dessous, les réflectances acquises dans certaines longueurs d'onde du moyen infrarouge ( $1.5 - 2.5 \mu m$ ) sont fortement sensibles au contenu en eau du sol et de la végétation et permettent également de différencier les surfaces enneigées des nuages par exemple. **Ainsi, grâce aux signatures spectrales des surfaces, il est possible de les distinguer les unes des autres et d'avoir accès au comportement de variables physiques et biophysiques comme l'état de stress des plantes ([Courault et al., 2008](#)), l'humidité des sols ([Lampkin and Yool, 2004](#)) et de produire des cartes d'occupation du sol ([Stoian et al., 2019](#)).**



*Figure 4.1 : Réflectances de différents types de sol acquises dans le visible - proche infrarouge (d'après Demarez, 2013).*

#### 4.1.1.2 Les capteurs optiques pour l'observation de la Terre

Dans les parties précédentes, nous avons pu voir l'apport de l'acquisition des réflectances dans le domaine optique (visible à moyen infrarouge) pour étudier le fonctionnement des surfaces. Ainsi, pour permettre un suivi systématique de la surface terrestre, de nombreux satellites embarquant des capteurs optiques ont été lancés dans l'espace durant les cinquante dernières années (voir tableau 4.1 pour une synthèse des principaux capteurs).

Le premier satellite dédié à l'observation de la Terre fut Landsat-1. Lancé en 1972 par la NASA (National Aeronautics and Space Administration) et l'USGS (United States Geological Survey), ce satellite américain emportait un capteur multispectral qui a permis de mesurer les réflectances de surface dans quatre bandes spectrales : le bleu, le vert, le rouge et le proche infrarouge. Il fut le premier d'une longue série de huit satellites (Landsat-8 dernièrement lancé en 2013; Roy et al., 2014) qui, de par leur large couverture au sol (fauchée de 185 km) et leur résolution spatiale décimétrique, ont permis le suivi à la fois global et local de changements de phénomènes anthropogéniques, tels que l'occupation du sol (Hansen and Loveland, 2012), ou de phénomènes à la fois naturels et anthropogéniques tels que l'évolution des forêts (Huang et al., 2010). Les satellites Landsat présentent la plus longue série de données en télédétection spatiale, rendant possible l'étude sur plusieurs décennies du changement climatique (Irons et al., 2012).



Par la suite, d'autres programmes spatiaux ont suivi la lignée de Landsat tels que le programme français SPOT (Satellites Pour l'Observation de la Terre). Celui-ci a mis en orbite sept satellites entre 1986 et 2014, ayant comme principal avantage par rapport à Landsat de pouvoir modifier l'angle d'observation de leur capteur multispectral. Cela a permis d'acquérir des images avec une répétitivité presque journalière (tous les 2-3 jours), et ainsi de réaliser une étude quotidienne de la végétation ([Castillo-Santiago et al., 2010](#)), voire même de faire un suivi en temps réel des inondations ([Smith, 1997](#)). De plus, grâce à l'expérience Take-5 ([Hagolle et al., 2015b](#); [Navarro et al., 2016](#)), les satellites SPOT 4-5 ont contribué à montrer l'intérêt des données satellitaires à forte répétitivité temporelle et haute résolution spatiale, et notamment à préparer la mission Sentinel-2. Cette mission a été menée par l'ESA (European Space Agency) avec le lancement en 2015 et 2017 de deux satellites fournissant des images multispectrales à 10 m de résolution, tous les 5 jours, et avec un même angle d'observation (cf. section 4.2.2). Cette dernière caractéristique a permis aux données Sentinel-2 de bénéficier de corrections atmosphériques (et détection de nuages) via la chaîne MAJA (cf. section 4.2.3). Avant application sur Sentinel-2, cette chaîne avait été préalablement testée et calibrée grâce au satellite taiwanais Formosat-2 (lancé en 2004), qui possède des caractéristiques proches de celles de Sentinel-2 ([Hagolle et al., 2010, 2015a](#)).

Parmi les satellites permettant un suivi quotidien des surfaces, nous pouvons également citer les deux satellites américains Terra et Aqua, lancés respectivement en 1999 et 2002, embarquant le capteur MODIS (section 3.2.2). Celui-ci a pour particularité de fournir des images dites hyperspectrales, c'est-à-dire acquises sur un nombre très important de bandes : MODIS possède 36 bandes spectrales réparties du visible ( $0.4 \mu\text{m}$ ) à l'infrarouge thermique ( $14.4 \mu\text{m}$ ). Cependant, ce capteur possède une résolution spatiale située entre 250 m et 1 km selon les bandes. Cette moyenne résolution est bien plus faible que celle des précédents satellites et peut être par conséquent inadaptée pour l'étude locale des processus de surface.

Pour détecter la variabilité fine échelle des surfaces, des capteurs optiques à très haute résolution spatiale ont également été développés. Ils ont été embarqués notamment par le satellite américain Ikonos lancé en 1999, ou encore par les deux satellites français Pléiades, lancés en 2011 et 2012, délivrant des images multispectrales à moins de 5 m de résolution. Ils peuvent ainsi fournir une information sur la surface avec un niveau de détails important, ce qui s'est avéré utile dans des applications telles que la gestion des catastrophes naturelles ([Stumpf et al., 2014](#)), l'analyse de la qualité de l'eau ([Ekercin, 2007](#)), le suivi des glaciers ([Holzer et al., 2015](#)) ou encore l'urbanisme ([Lee et al., 2003](#)).

Récemment, le microsatellite franco-israélien Venµs a été mis en orbite en 2017. Grâce à sa résolution de 5 m, sa répétitivité de 2 jours et ses 12 bandes spectrales, il rassemble plusieurs caractéristiques qui lui permettent de réaliser un suivi fin et régulier de la végétation

terrestre à des échelles régionales (Dedieu et al., 2007). Cela contribuera à apporter des réponses sur des questions scientifiques telles que l'influence de facteurs environnementaux, des activités humaines et des changements climatiques sur les surfaces continentales. De plus, son angle de visée constant lui confère la possibilité de bénéficier des corrections atmosphériques multi-temporelles de la chaîne MAJA (produits corrigés disponibles sur la plateforme THEIA : <https://theia.cnes.fr>).

Capteur	Résolution	Répétitivité	Bandes spectrales
MODIS	1 km	1 jour	VIS - PIR - MIR - THERM (36 bandes)
Landsat 1-3	80 m	18 jours	VIS - PIR - THERM (< 10 bandes)
Landsat 4-8	30 m	16 jours	
SPOT 1-4	20 m	26 jours (2-3 j en dépointage)	VIS - PIR - MIR (~ 5 bandes)
SPOT 5	10 m	26 jours	
SPOT 6,7	6 m	1-3 jours	
Sentinel-2	10 m	5 jours	VIS - PIR - MIR (13 bandes)
Formosat-2	8 m	1 jour	VIS - PIR (4 bandes)
Venµs	5 m	2 jours	VIS - PIR (12 bandes)
Ikonos	4 m	3-5 jours	VIS + PIR (5 bandes)
Pléiades	2 m	1 jour	

**Tableau 4.1 : Description des principaux capteurs optiques dédiés à l'observation de la Terre (VIS = visible, PIR = proche infrarouge, MIR = moyen infrarouge, THERM = infrarouge thermique). Ici les bandes panchromatiques (définies sur une large gamme de longueurs d'onde) ne sont pas prises en compte dans la résolution spatiale du capteur, celle-ci étant généralement supérieure dans ces bandes.**

#### 4.1.2 Analyse de l'hétérogénéité spatiale des images optiques

Par l'intermédiaire des capteurs multispectraux, les images optiques permettent d'accéder à l'hétérogénéité des surfaces continentales, qui est due aux effets combinés de facteurs naturels et anthropiques. **Etant données l'action à différentes échelles spatiales et différentes longueurs d'onde de ces facteurs, l'analyse de l'information contenue dans les réflectances de surface peut s'avérer complexe en termes de technique de traitement d'image.** Différentes méthodes d'extraction de l'information ont été développées et utilisées

jusqu'ici, dépendant de l'application. Un descriptif général de ces méthodes se trouve en sections 2.1.2 et 2.1.3: nous pouvons rappeler par exemple des techniques d'assimilation de données pour l'intégration d'images satellites dans des modèles de surface, des algorithmes de classification pour produire des cartes d'occupation du sol, ou encore des méthodes basées sur l'analyse multi-échelle de la variabilité spatiale. **Cette dernière famille de méthodes a pour vocation d'extraire les propriétés spatiales des images optiques pour en décrire leur complexité.** Ces techniques utilisent des notions et des outils statistiques tels que les spectres de puissance, l'entropie, les variogrammes, les ondelettes ou la dimension fractale (section 2.1.3).

Suite à l'apparition du terme "fractal" introduit par [Mandelbrot \(1967\)](#), de nombreux travaux basés sur la notion de fractale géométrique ont été menés afin d'étudier la complexité de phénomènes géophysiques tels que les traits de côte ([Shelberg et al., 1982](#)), la topographie ([Mark and Aronson, 1984](#)) ou la pluie et les nuages ([Lovejoy and Mandelbrot, 1985](#)). Les premières analyses monofractales appliquées aux réflectances de surfaces ont été réalisées quelques années plus tard sur des images multispectrales issues de Landsat-5. [De Cola \(1989\)](#) a effectué l'analyse fractale de produits d'occupation du sol obtenus après classification des produits Landsat-5 sur une région de l'état du Vermont (Etats-Unis). La dimension fractale  $D_f$  a été estimée selon la relation utilisée dans [Lovejoy \(1982\)](#) liant les périmètres  $P$  et aires  $A$  obtenus pour chaque objet issu de la classification :

$$P \sim \sqrt{A^{D_f}}$$

4.6

Ici, l'aire est calculée en comptant le nombre de pixels des objets (selon la méthode du "box-counting"; [Mandelbrot, 1967](#)). Le périmètre est obtenu en mesurant la longueur des limites de chaque élément. Ainsi, cette étude a pu mettre en évidence le caractère fractal de huit classes de surface (forêt, urbain, rural...) pour des échelles spatiales situées entre 30 m et 60 km, et a montré que la dimension fractale était directement liée à ces classes. En effet, des dimensions élevées ont été obtenues pour les surfaces couvertes de feuillus ou correspondant à des zones urbaines, révélant des périmètres complexes, alors que de faibles dimensions fractales ont été estimées pour les zones rurales, liée à la structure des parcelles qui créent des régions à périmètres répétitifs.

Ces travaux ont été complétés par ceux de [Lam \(1990\)](#) qui a effectué l'analyse fractale des réflectances de chaque bande spectrale de Landsat-5, sur trois types de surfaces (urbain, rural, côtier) situées en Louisiane (Etats-Unis). Les dimensions fractales ont été calculées pour des échelles entre 25 m et 150 m, en déterminant les contours des objets de l'image par la méthode des lignes isarithmes ([Shelberg et al., 1983](#)). Les résultats ont révélé des valeurs de dimensions fractales plus élevées ( $>2.5$ ) que celles obtenues jusque-là dans la littérature, notamment en topographie ([Roy et al., 1987](#); [Shelberg et al., 1983](#)), montrant la forte

complexité des images optiques qui combinent les variabilités issues de la topographie et de la surface même (occupation du sol). De plus, une diminution de la dimension fractale avec la longueur d'onde a été observée dans le domaine du visible à proche infrarouge, ainsi que des valeurs différentes selon l'occupation du sol (dimension élevée en zone urbaine et faible en zone rurale). Par la suite, quelques études ont poursuivi l'analyse fractale des surfaces dans le domaine optique, notamment les travaux de [Qiu et al. \(1999\)](#) qui ont exploré plus en détails le lien entre domaine spectral et dimension fractale grâce aux images hyperspectrales (224 bandes) du capteur aéroporté AVIRIS (Airborne Visible InfraRed Imaging Spectrometer; [Vane et al., 1993](#)). Ils ont montré que des valeurs anormalement élevées de dimension fractale ( $>2.9$ ) étaient obtenues pour les bandes situées dans les domaines d'absorption et de diffusion de l'atmosphère – phénomène lié au fort bruit aléatoire présent dans ces longueurs d'onde.

Les travaux évoqués ci-dessus portaient sur les études monofractales existantes. Ce n'est que récemment que certains travaux de recherche se sont consacrés à l'analyse des comportements multifractals des réflectances de surfaces. En particulier, les travaux de [Lovejoy et al. \(2008b\)](#) ont mis en évidence, pour la première fois, les propriétés multifractales de réflectances de surface issues de sept bandes spectrales du capteur MODIS (visible, proche et moyen infrarouge), sur une région située dans le centre de l'Espagne, et pour des échelles comprises entre 500 m et 25 km. Cette analyse a montré l'intérêt du modèle stochastique des Multifractals Universelles ([Schertzer and Lovejoy, 1987](#); ou voir section 2.2.3) pour révéler les lois d'échelles et ainsi la forte complexité des processus de surface acquis par images optiques. Les paramètres universels  $H$  et  $C_1$  obtenus pour l'ensemble des bandes ( $H \approx 0.19$ ,  $C_1 \approx 0.04$ ) se sont avérés significativement différents de ceux estimés dans d'autres domaines de la littérature tels que la turbulence ( $H = 0.3$ ,  $C_1 = 0.09$ ; [Schmitt et al., 1993](#)), la topographie des surfaces et des océans ( $H = 0.4 - 0.7$ ,  $C_1 = 0.12$ ; [Gagnon et al., 2006](#)) ou les nuages ( $H = 0.2 - 0.5$ ,  $C_1 = 0.08$ ; [Lovejoy and Schertzer, 2006](#)). En revanche, le paramètre  $\alpha$  présente des valeurs fortement similaires à la littérature ( $\alpha = 1.9 - 2$ ). [Lovejoy et al. \(2008b\)](#) ont également réalisé l'analyse d'indices optiques de végétation et d'humidité, montrant que ces derniers vérifiaient aussi des lois d'échelles, notamment multifractales. Par ailleurs, cette étude a mis en évidence la nécessité de proposer des méthodes d'estimation d'indices qui considèrent et respectent les dépendances inter-échelles des processus de surfaces – ce qui n'est pas le cas via les méthodes actuelles. En effet, les bandes permettant d'estimer les indices sont combinées à la résolution du capteur, et fournissent ainsi des indices dont les statistiques ne sont correctes qu'à cette résolution, altérant donc les lois d'échelle.

Plus récemment, ces résultats ont été complétés par l'étude d'[Alonso et al. \(2017\)](#) portant sur l'analyse multifractale de réflectances de surface acquises par les satellites Ikonos et Landsat-7 dans quatre bandes spectrales (bleu, vert, rouge, proche-infrarouge), également sur une région au centre de l'Espagne. Ces travaux ont mis en application une autre méthode d'analyse multifractale appelée la "Méthode des moments" ([Halsey et al., 1986](#)). Comme pour

le modèle des Multifractales Universelles, cette méthode consiste à estimer les moments empiriques pour différents ordres  $q$  et différentes échelles spatiales (ou tailles de pixel  $\delta$ ). Le comportement de ces moments est ensuite comparé au comportement multifractal théorique, représenté par la loi puissance :

$$\chi(q, \delta) \sim \delta^{\tau(q)}$$

4.7

Ici, la fonction  $\tau(q)$  est comparable à la fonction d'échelle  $K(q)$  – certaines études ont montré le lien entre ce modèle et celui des Multifractales Universelles ([Aguado et al., 2014](#)). Bien qu'elle ne spécifie pas de paramétrisation particulière (contrairement au modèle des Multifractales Universelles), cette technique permet de caractériser le comportement multifractal des images et a été appliquée dans plusieurs domaines géophysiques tels que la topographie ([Hu et al., 2009](#)) ou la surface des océans ([Tarquis et al., 2014](#)). Ici, [Alonso et al. \(2017\)](#) ont mis en évidence l'impact de la résolution spatiale d'acquisition des images sur leurs propriétés multifractales. En effet, pour une même gamme d'échelles (120 m – 15 km), les paramètres d'échelles des bandes spectrales se sont avérés différents selon que celles-ci aient été acquises à très haute résolution (4 m via Ikonos) ou à haute résolution spatiale (30 m via Landsat-7). De plus, l'analyse a permis de confirmer certains phénomènes observés précédemment, tels que l'influence de la bande spectrale sur les lois d'échelle ([Lam, 1990](#)), et une altération des propriétés multifractales d'indices de végétation ([Lovejoy et al., 2008b](#)).

A ce jour, les études de [Lovejoy et al. \(2008b\)](#) et d'[Alonso et al. \(2017\)](#) sont conceptuellement les plus proches du travail détaillé dans le présent chapitre. L'analyse multifractale a en effet été assez rarement appliquée à des données de réflectances de surfaces continentales (comparé à d'autres domaines des géosciences). Cela est en partie due au contexte historique des modèles multifractals initialement développés dans le domaine de la turbulence ([Parisi and Frisch, 1985](#); [Schertzer and Lovejoy, 1987](#)), ce qui a mené à beaucoup de travaux sur la dynamique des processus atmosphériques ([Lovejoy et al., 2008a](#); [Lovejoy and Schertzer, 2010c](#)) mais à un nombre d'études bien plus restreint sur les surfaces continentales. **De plus, une contrainte majeure dans l'étude des surfaces par capteur optique est la présence de l'atmosphère.** Certains de ses composants tels que les aérosols, les molécules de gaz ou les nuages impactent le signal acquis par le satellite et peuvent artificiellement modifier les propriétés d'échelle de la surface. Par exemple, plusieurs travaux ont montré le comportement multifractal des nuages observés par capteurs optiques ([Lovejoy et al., 2001](#); [Siebesma and Jonker, 2000](#); [Tessier et al., 1993](#)). Pour éviter l'effet des nuages sur les réflectances de surface, les études de [Lovejoy et al. \(2008b\)](#) et d'[Alonso et al. \(2017\)](#) ont porté sur une ou deux dates particulières, choisies spécifiquement pour fournir des images sans nuages. **Ainsi, aucune dynamique temporelle des propriétés multi-échelles des surfaces n'a été réellement explorée à ce jour.**

### 4.1.3 Apport de la correction atmosphérique dans l'étude de la dynamique temporelle des propriétés d'échelle


Dans notre étude, nous souhaitons ajouter une composante temporelle à l'analyse de l'hétérogénéité spatiale des surfaces continentales afin d'observer comment évoluent les propriétés multi-échelles des réflectances au cours d'une année complète. De par son impact significatif sur les rayonnements optiques, l'atmosphère est la principale limitation à l'étude de cette dynamique temporelle. Dans cette partie, nous allons détailler les effets de l'atmosphère sur les réflectances, puis nous présenterons les diverses techniques utilisées à ce jour pour corriger ces effets dans le cas des molécules et aérosols, et les détecter afin de les éviter dans le cas des nuages.

#### 4.1.3.1 Composition de l'atmosphère et impact sur les réflectances de surface

L'atmosphère est un milieu turbide d'environ 100 km d'épaisseur qui se compose de trois types d'éléments. Tout d'abord, en plus grande proportion nous trouvons les molécules de gaz : l'azote (N) à près de 78%, l'oxygène (O<sub>2</sub>) à 21%, puis en plus faible quantité l'ozone (O<sub>3</sub>), le dioxyde de carbone (CO<sub>2</sub>) et la vapeur d'eau (H<sub>2</sub>O). Cette dernière est fortement variable, même localement, et peut s'avérer plus complexe à détecter et à estimer que les autres gaz qui sont distribués de manière homogène dans l'atmosphère. La deuxième famille de composants comprend l'ensemble des fines particules solides ou liquides en suspension dans l'atmosphère : les aérosols. Ils peuvent être de taille variable (0.1 à 10  $\mu$ m), d'origine naturelle (poussières désertiques, embruns marins, cristaux de glace...) ou anthropogénique (fumées, poussières industrielles...). Leur distribution hétérogène rend leurs détection et estimation difficiles, et est encore aujourd'hui le sujet de nombreux travaux sur les corrections atmosphériques ([Dubovik et al., 2002](#); [Hagolle et al., 2015a](#); [King et al., 1999](#)). Enfin, les nuages sont également un constituant de l'atmosphère. Formés de gouttelettes d'eau en suspension, ils se distinguent de la vapeur d'eau (qui est à l'état gazeux) de par l'impact important qu'ils vont avoir sur les rayonnements solaires émis ou réfléchis (allant souvent jusqu'à l'obstruction totale). Tout comme les aérosols, ils sont fortement variables mais nous allons voir dans la suite qu'ils sont plus simples à détecter. Ces divers éléments de l'atmosphère impactent les rayonnements solaires de deux manières différentes : par absorption ou par diffusion. Le premier phénomène est causé par les molécules de gaz qui vont absorber les photons émis par le Soleil. Cela se produit à des longueurs d'onde précises, appelées "pics d'absorption", qui correspondent à la fréquence de résonance des molécules et à celle du rayonnement. L'ozone par exemple absorbe essentiellement dans l'ultraviolet (400 – 10 nm), le dioxygène dans une bande étroite du proche infrarouge (~ 760 nm), la vapeur d'eau et le dioxyde de carbone présentent plusieurs pics d'absorption qui peuvent être de largeur importante surtout dans l'infrarouge. Cela peut s'observer sur la figure 4.2 qui compare l'éclairement




solaire hors atmosphère (correspondant à celui d'un corps noir), et le même éclairement obtenu au niveau de la mer (affecté des effets d'absorption).



**Figure 4.2 : Impact de l'absorption par les molécules atmosphériques sur l'éclairement solaire (d'après Kergomard, 1990).**

Le second phénomène, dit de diffusion, correspond quant à lui à la déviation des rayonnements solaires par les molécules, les aérosols ou les nuages. Dans ce cas, les photons vont subir plusieurs réflexions au contact de ces composants qui vont avoir pour conséquence de modifier la direction de propagation de la lumière. Pour les nuages, la densité des gouttelettes en suspension est si importante que presque la totalité du rayonnement est réfléchi, ne permettant pas la transmission des rayons vers la Terre, et ce quelle que soit la longueur d'onde. Il s'agit du cas extrême de diffusion. Pour les aérosols ou les molécules, le phénomène est moins radical, ayant surtout comme effet de dévier le rayonnement. Dans le cas des molécules, on parle de diffusion [Rayleigh \(1871\)](#) : seules les courtes longueurs d'onde sont affectées (responsables de la couleur bleue du ciel) et l'effet est isotrope, se produisant de manière égale dans toutes les directions. Pour les aérosols, il s'agit de la diffusion de Mie ([Born and Wolf, 1970](#)) : l'ensemble du spectre est affecté (d'où la couleur blanchâtre du ciel en cas de pollution), l'effet est anisotrope se produisant dans les directions proches de celle du rayonnement initial. De manière générale, le phénomène de diffusion se produit essentiellement dans les domaines du visible et proche infrarouge. A l'inverse du phénomène d'absorption qui peut être contourné en évitant les pics d'absorption ou en connaissant l'impact de chaque molécule sur les rayons, la diffusion demande de prendre en compte

plusieurs effets combinés (fig.4.3), tels que la diffusion directe des rayons solaires sur l'atmosphère (appelée "luminance propre de l'atmosphère"), la diffusion des rayons réfléchis par la surface, ou encore les effets d'environnement dans le cas de surfaces hétérogènes (Tanré et al., 1987).



**Figure 4.3: Impact de l'atmosphère en télédétection optique (d'après Tanré et al., 1986).**

#### 4.1.3.2 Méthodes de correction atmosphérique

Les différentes méthodes opérationnelles utilisées aujourd'hui pour corriger les réflectances des effets atmosphériques se basent sur des équations de transfert radiatif (Lenoble et al., 2007; Rahman and Dedieu, 1994; Tanré et al., 1990). Ces équations modélisent le trajet des rayonnements solaires dans l'atmosphère en fonction des propriétés des molécules et aérosols qui le composent (type de composant, quantité...). En particulier, les effets de diffusion et d'absorption précédemment évoqués peuvent ainsi être estimés et corrigés de manière à obtenir le signal d'intérêt, c'est-à-dire les réflectances de surface non perturbées par l'atmosphère. L'équation ci-dessous présente un exemple simplifié d'équation de transfert radiatif (Tanré et al., 1990) :

$$\rho_{TOA} = t_g \left( \rho_{TOC} \frac{T_{dir+diff}}{1 - S \cdot \rho_{TOC}} + \rho_a \right)$$

4.8

où  $\rho_{TOA}$  et  $\rho_{TOC}$  sont respectivement les réflectances "Top Of Atmosphere" (impactée des effets atmosphériques) et "Top of Canopy" (signal d'intérêt).  $t_g$  représente les effets d'absorption (ou de transmission) des molécules de gaz. Le paramètre  $T_{dir+diff}$  correspond aux effets de diffusion des molécules et aérosols sur les photons, ainsi que les effets de transmission directe des photons réfléchis par la surface sans interaction avec l'atmosphère. Cette équation prend également en compte des caractéristiques de l'atmosphère telles que sa réflectance propre  $\rho_a$  (diffusion sans interaction avec la surface), ainsi que son albédo  $S$  qui correspond à la moyenne de la réflectance acquise dans toutes les directions et sur tout le spectre (Tupin et al., 2014).

Différents modèles ont été proposés à ce jour (Lenoble, 1985; Royer et al., 1988) : parmi les plus anciens nous pouvons citer des modèles développés dans les années 90, pour la plupart par la NASA, comme celui de Turner and Spencer (1972), Lowtran 6 (Kneizys et al., 1988) ou encore le modèle 5S (Simulation of the Satellite Signal in the Solar Spectrum; Tanré et al., 1990). Ces modèles se sont avérés trop coûteux en temps de calcul pour être appliqués de manière opérationnelle aux images acquises par les satellites américains de l'époque tels que Landsat ayant un champ de vue très large. Par la suite, des modèles plus simples, plus rapides et ainsi mieux adaptés au traitement opérationnel d'images de grandes tailles ont été développés tels que les modèles 6S (Second Simulation of the Satellite Signal in the Solar Spectrum; Vermote et al., 1997), SMAC (Simplified Method for Atmospheric Corrections; Rahman and Dedieu, 1994) ou SOS (Successive Order of Scattering; Lenoble et al., 2007). Ces deux derniers modèles sont par exemple appliqués de manière opérationnelle dans la chaîne de correction atmosphérique MAJA (cf. section 4.2.3), pour le traitement de données Landsat-8 et Sentinel-2.

De manière simplifiée, les équations appliquées par ces différents modèles ont pour point commun d'estimer, pour chaque bande spectrale, des coefficients représentatifs de l'impact des molécules ou des aérosols sur le rayonnement (paramètres  $t_g$ ,  $T_{dir+diff}$ ,  $\rho_a$  et  $S$  dans l'équation 4.8). Cela est possible grâce à l'utilisation de tables LUT (Look Up Tables; Fraser et al., 1985; Lenoble et al., 2007) qui font correspondre à chaque type de composant un certain coefficient. Ces tables étant pour la plupart du temps déjà connues, la difficulté réside surtout dans l'identification précise des propriétés (type, concentration) des éléments atmosphériques. Un récapitulatif des méthodes utilisées pour estimer ces éléments est présenté en figure 4.4. Il ne s'agit pas de faire une liste exhaustive, mais de présenter les différents types de méthodes que l'on peut retrouver dans les chaînes opérationnelles de correction atmosphérique. Pour ce qui est des molécules de dioxygène, d'ozone et de dioxydes de carbone, l'estimation de leur quantité ne présente pas de contrainte particulière étant donnée leur répartition homogène dans l'atmosphère. Plus variable, la vapeur d'eau nécessite quant à elle d'être estimée localement. Pour cela, les modèles peuvent utiliser des

données météorologiques, voire même bénéficier des bandes spécifiques de certains capteurs dédiées à l'estimation de la vapeur d'eau (Sentinel-2, Venµs, section 4.2.3.2).

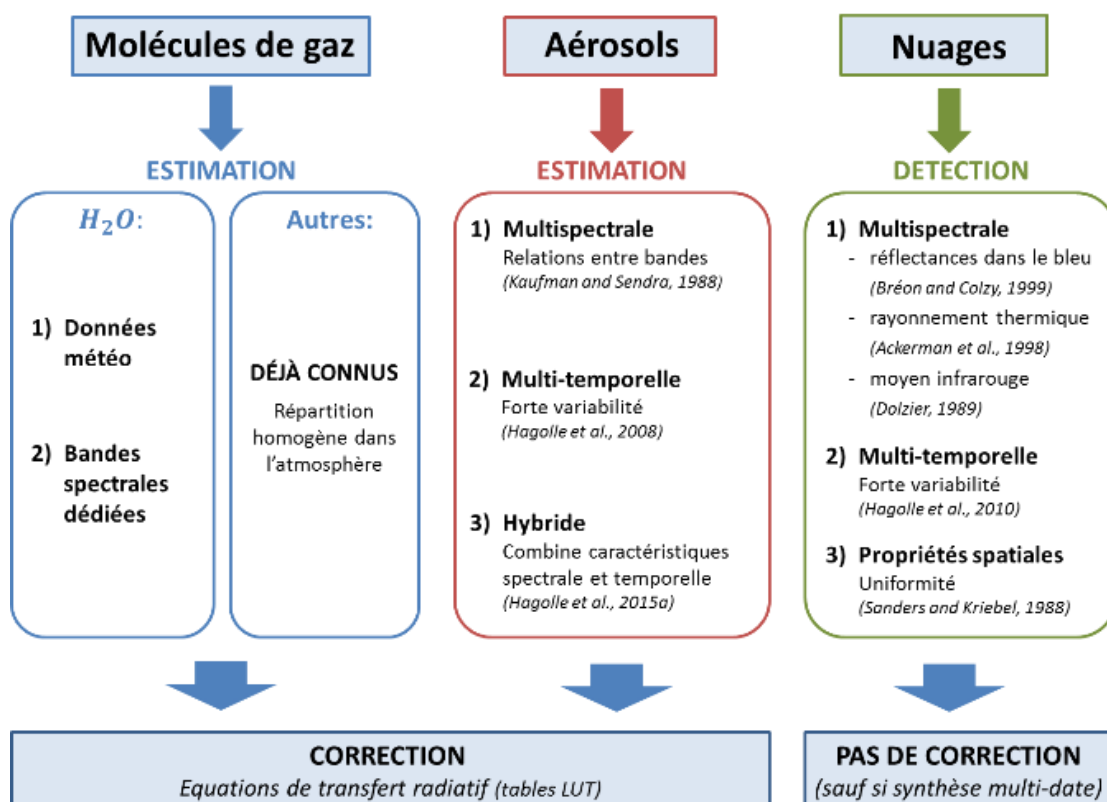


Figure 4.4 : Schéma récapitulatif des différentes méthodes d'estimation et de détection des composants atmosphériques.

Les aérosols sont très variables à la fois spatialement et temporellement, ce qui les rend difficiles à identifier et à estimer (Dubovik et al., 2002; King et al., 1999). Plusieurs techniques ont été élaborées et appliquées pour tenter de déterminer avec précision leur concentration dans l'atmosphère ou "AOT" (Aerosol Optical Thickness). Les plus populaires sont les méthodes multispectrales qui se servent des relations entre différentes bandes spectrales pour estimer la quantité d'aérosols (Kaufman and Sendra, 1988). Cependant, ces méthodes ne fonctionnent que dans le cas où la surface est composée de zones à végétation dense. Bien que cette contrainte ait pu être contournée pour certains capteurs – tels que MODIS bénéficiant d'une bande dédiée à la détection d'aérosols dans le bleu ("Deep Blue Band"; Sayer et al., 2013; Levy et al., 2013) – l'efficacité des méthodes multispectrales est restée limitée car trop dépendante de la surface qui peut varier au cours des saisons. D'autres techniques, dites multi-temporelles (Hagolle et al., 2008), mettent à profit la forte variabilité temporelle des aérosols par rapport à la surface qui varie peu au cours du temps (Hall et al., 1991; Tanré et al., 1988). Les fortes variations de réflectances détectées entre deux images successives peuvent ainsi être associées aux variations des aérosols et être utilisées pour

estimer l'AOT. Cette méthode a l'avantage de fonctionner quelle que soit l'occupation du sol, et indépendamment des changements de la surface se produisant par exemple lors des périodes de récoltes ou de semis, ou lors de catastrophes naturelles. Toutefois, cette technique est applicable sous réserve d'une répétitivité temporelle suffisante du satellite ou encore d'un angle de visée constant, ce qui est le cas des satellites récents comme Sentinel-2, Landsat-8 ou encore Venus. Récemment, Hagolle et al. (2015a) ont créé une méthode hybride qui tire profit des approches multispectrale et multi-temporelle. Compte-tenu des meilleures performances de la méthode hybride, cette dernière a été implémentée de manière opérationnelle dans la chaîne de traitement atmosphérique MAJA (Hagolle et al., 2015a; Rouquié et al., 2017; section 4.2.3).

Concernant les nuages, les traitements consistent principalement à les détecter dans les images de manière automatique. Il y a quelques années, la détection de nuages se faisait encore manuellement en raison du coût des images et de leur accessibilité limitée ne facilitant pas l'étude de séries temporelles. La détection automatique s'est surtout développée depuis la mise à disposition gratuite des images Landsat ou plus récemment Sentinel-2. Cependant, les toutes premières méthodes ont été développées et testées un peu avant cela sur des capteurs à moyenne résolution spatiale tels que MODIS, AVHRR (Advanced Very High Resolution Radiometer) ou POLDER (POLarization and Directionality of the Earth's Reflectances). Ces méthodes se basaient essentiellement sur les propriétés spectrales des nuages pour les identifier, telles que leur forte réflectance dans le bleu (Bréon and Colzy, 1999), leur rayonnement thermique plus faible que la surface (Ackerman et al., 1998) ou leur forte réflectance dans le moyen infrarouge permettant de les distinguer de la neige (Dozier, 1989). En plus de ces propriétés, les caractéristiques spatiales des nuages – plus uniformes que la surface – peuvent être utilisées pour améliorer leur détection (Saunders and Kriebel, 1988). Aujourd'hui, des algorithmes opérationnels ont été élaborés à partir de ces méthodes fournissant de manière automatique des masques de nuages aux utilisateurs. Parmi les processeurs intégrant ce type d'algorithmes, les plus connus sont le processeur Sen2Cor de l'ESA (Louis et al., 2016) appliqué aux images Sentinel-2, et le processeur FMask de l'USGS (Zhu et al., 2015) initialement développé pour les images Landsat. Nous pouvons également citer des méthodes utilisant des algorithmes d'apprentissage tels que les réseaux de neurones pour améliorer la classification des pixels "nuageux" (Hughes and Hayes, 2014; Zhan et al., 2017). Enfin, une autre possibilité pour détecter les nuages est de se servir de leur forte variabilité temporelle (Lyapustin et al., 2008; Reuter and Fisher, 2004). De la même manière que les aérosols, si une forte variation de réflectance dans le bleu (selon un seuil bien défini) est observée entre deux images successives, alors celle-ci sera associée à la présence d'un nuage. Récemment, Hagolle et al. (2010) ont proposé la méthode MTCD (Multi-Temporal Cloud Detection) qui a été intégrée de manière opérationnelle dans la chaîne MAJA (qui sera détaillée à la section 4.2.3). Cette méthode a présenté des performances égales voire

supérieures à celles de méthodes mono-temporelles (Baetens et al., 2019), montrant ainsi l'apport de l'aspect multi-temporel dans la détection de nuage. En plus de la détection des nuages, certains algorithmes proposent une détection de leur ombre (Hagolle et al., 2010; Hughes and Hayes, 2014). La plupart des méthodes ont recours aux propriétés spectrales des ombres qui sont plus sombres que la surface (Martinuzzi et al., 2007; Wang et al., 1999), ainsi qu'à leurs propriétés temporelles (Goodwin et al., 2013) et géométriques (Hégarat-Masclé and André, 2009; Lissens et al., 2000).

Dans cette partie introductive, nous venons de voir en quoi les données multispectrales permettaient d'avoir accès à la variabilité spatiale des processus physiques et biophysiques des surfaces continentales. Parmi diverses méthodes de traitements d'image, l'analyse multi-échelle est une technique qui s'est avérée intéressante et originale pour étudier cette hétérogénéité. Bien que l'atmosphère ait un impact certain sur les données optiques, nous avons vu que de nombreuses méthodes de correction existent pour limiter au mieux cet effet et permettre un suivi temporel régulier des surfaces.

## 4.2 Cas d'étude et données

### 4.2.1 Zone d'étude

#### 4.2.1.1 La région Sud-Ouest

Le Sud-Ouest de la France est un site fortement anthropisé qui se compose en majeure partie de surfaces agricoles. En effet, plus de la moitié des surfaces au sol est exclusivement dédiée au développement et à la gestion de cultures, et ce tout au long de l'année. Parmi les plus présentes, nous pouvons trouver les cultures de tournesol, maïs, blé, orge, soja et colza. En considérant également les zones urbaines qui constituent ~ 2% du paysage, la région Sud-Ouest possède une structure spatiale qui est en grande partie caractérisée par des facteurs anthropiques. Ces derniers ont un impact sur la variabilité spatiale des processus physiques et biophysiques tels que la température de surface, l'humidité des sols ou la végétation. Des facteurs naturels jouent également un rôle non négligeable dans la structuration spatiale de ce paysage et des processus, comme par exemple les prairies (~ 32% de la surface) et les forêts (~ 8%) (Baup et al., 2015).

La région Sud-Ouest possède un climat tempéré qui induit des effets saisonniers impactant de manière significative la dynamique temporelle des processus. De fortes pluies sont présentes au cours du printemps et les étés sont chauds et secs, avec des températures qui atteignent souvent les 35°C (Battude, 2017). Ces conditions climatiques ont un effet direct

sur la structure du paysage et plus particulièrement sur l'évolution de cette structure au cours des saisons. En effet, les cycles de cultures – décrits par des périodes de récolte et de semis – contribuent à modifier l'hétérogénéité de la surface au fur et à mesure des saisons. De plus, la différenciation culture d'hiver / culture d'été sous-entend que toutes les cultures n'ont pas la même évolution saisonnière et n'affectent pas de la même manière la composition du sol au cours du temps.

#### 4.2.1.2 L'Observatoire Spatial Régional

Conscient des enjeux scientifiques et socio-économiques rattachés à cette région Sud-Ouest, le CESBIO a initié en 2006 la création de l'Observatoire Spatial Régional (OSR). Labellisé par l'Institut National des Sciences de l'Univers (INSU) depuis 2007, l'OSR est un dispositif d'organisation des systèmes d'observation du CESBIO et de partenaires locaux dont le but est de faciliter l'accès aux données et résultats scientifiques. Sa zone géographique correspond à l'ensemble du bassin Adour-Garonne, qui s'étend de la chaîne des Pyrénées au Sud jusqu'au Massif Central au Nord, et comprenant les départements du Gers (Ouest), de la Haute-Garonne (centre) et une partie de l'Ariège (Est). La finalité de cet observatoire est de répondre à des questions scientifiques liées au fonctionnement et à l'évolution des surfaces continentales, mais aussi de traiter des problématiques plus appliquées en lien avec l'aménagement du territoire et la gestion durable des ressources (Dejoux et al., 2012).

Une particularité de ce dispositif est sa dimension régionale, comprenant l'échelle du paysage, du bassin versant et des régions. Ainsi, plusieurs moyens d'observation intervenant à différentes échelles spatiales sont utilisés de manière complémentaire. Des campagnes terrain permettent une étude localisée des surfaces grâce à des données de flux de carbone, d'eau et des données météorologiques acquises sur trois sites expérimentaux (Béziat et al., 2009; Burel, 2018; Tallec et al., 2013). A cela se rajoutent des données de télédétection (aéroportées et spatiales) qui fournissent un suivi continu et global de l'état de la végétation et de l'occupation du sol. En particulier, lors de la campagne MCM'10 (Multi-sensors Crop Monitoring; Baup et al., 2012) réalisée en 2010 sur la région Sud-Ouest, divers capteurs spatiaux à haute résolution spatiale (SPOT 4-5, Formosat-2), moyenne résolution (Advanced Land Observing Satellite) ou encore basse résolution (SMOS) ont montré le potentiel de la télédétection multi-capteur et multi-échelle pour étudier des surfaces hétérogènes. Grâce à ces données, plusieurs travaux portant sur le suivi des cultures par télédétection ont été menés sur cette région tels que l'étude du blé et du colza (Fieuzal et al., 2013) ou encore l'estimation par modèle agro-météorologique du rendement du tournesol (Fieuzal and Baup, 2015), du soja (Baup et al., 2015; Betbeder et al., 2016) et du maïs (Fieuzal et al., 2017). Ces études ont également permis de préparer les récentes missions spatiales telles que Venus ou Sentinel-2, menant par la suite à des travaux sur la modélisation de la biomasse et du rendement de cultures par données optiques à haute résolution spatiale (Ameline et al., 2018;

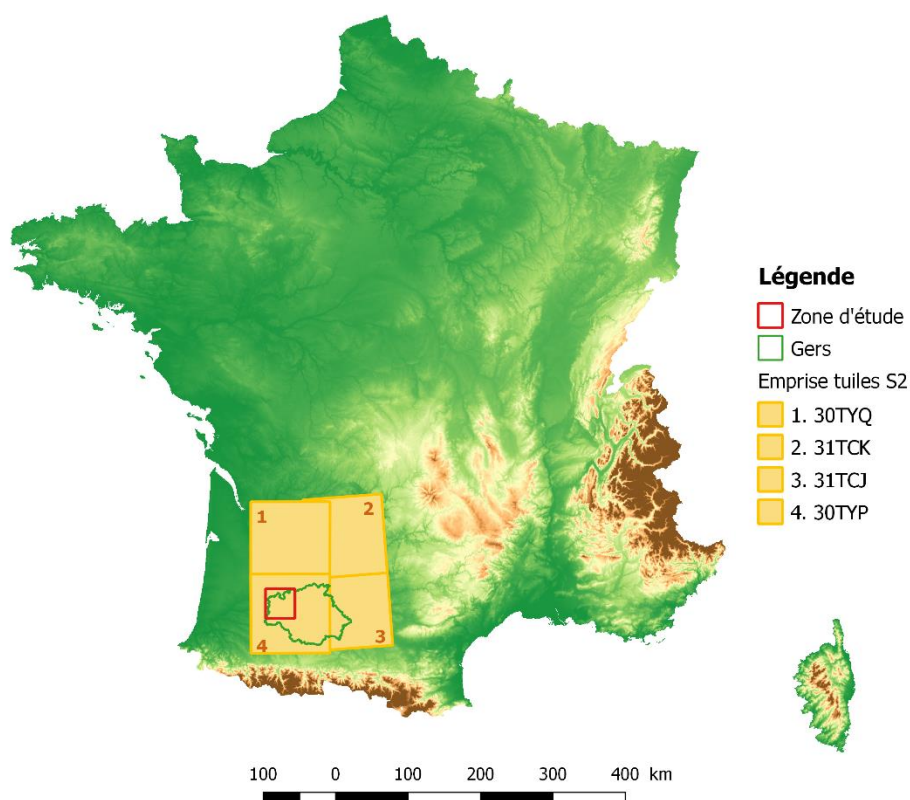


Battude et al., 2016; Claverie et al., 2012). Les produits optiques issus de ces nouveaux satellites bénéficient aujourd'hui d'une attention particulière dans cette région, puisqu'ils sont mis à disposition sur la plateforme THEIA (<https://theia.cnes.fr>), corrigés des effets de l'atmosphère par la chaîne de traitement MAJA (section 4.2.3).

#### 4.2.1.3 Sélection d'une zone d'étude dans le Gers

**De par l'hétérogénéité de ses surfaces et le nombre grandissant de données acquises à diverses échelles spatiales, la région Sud-Ouest est particulièrement bien adaptée à l'application d'outils d'analyse statistique multi-échelle comme ceux que nous proposons dans cette thèse.** C'est dans ce contexte que nous nous sommes intéressés aux réflectances de surfaces acquises sur cette région. Cette dernière correspond à l'emprise spatiale de quatre tuiles Sentinel-2 (voir section 4.2.2.3 sur le format des tuiles fournies par l'ESA) : 30TYP, 31TCJ, 30TYQ et 31TCK (fig.4.5). Plus particulièrement, nous avons focalisé notre étude sur une zone de 40 x 40 km<sup>2</sup> recouvrant une partie du département du Gers (carré rouge sur la fig.4.5) et se situant au sein de la tuile 30TYP. **Cette zone dans le Gers a été choisie car elle se compose en majeure partie de surfaces agricoles, limitant l'impact des zones urbaines (villes, routes) sur la variabilité spatiale des processus physiques et biophysiques.** De plus, de par certaines contraintes liées aux outils d'analyse (tailles des échantillons, temps de calcul) et à la couverture nuageuse (section 4.2.4), nous avons choisi de limiter notre zone d'étude et sélectionner une surface plus petite que celle correspondant aux tuiles Sentinel-2 qui recouvrent quant à elles une surface de 100 x 100 km<sup>2</sup>.

Cette étude a été réalisée sur l'ensemble de l'année 2016, correspondant à l'analyse d'images acquises par le satellite Sentinel-2A. Le second satellite Sentinel-2B ayant été lancé en mars 2017, ses produits opérationnels et corrigés des effets atmosphériques n'ont été disponibles qu'à partir de fin octobre 2017, ne nous permettant donc pas de bénéficier de ses images dans notre étude. Cependant, la répétitivité temporelle de chaque satellite pris à part est de dix jours. Cela reste suffisant dans le cadre de ce travail qui consiste à analyser la dynamique temporelle globale des propriétés des surfaces, sur une année entière. Pour finir, nous pouvons également souligner que la région Sud-Ouest possède une couverture nuageuse moyenne relativement faible tout au long de l'année, par comparaison à d'autres régions de France situées plus au Nord comme au Sud (Mangiarotti et al., 2018). Considérant l'impact que peuvent avoir les nuages sur les produits optiques (section 4.1.3), ce critère n'est donc pas négligeable dans le choix de la zone d'étude.



*Figure 4.5 : Région Sud-Ouest correspondant à l'emprise spatiale des quatre tuiles Sentinel-2 (jaune), et comprenant la zone d'étude (rouge) issue de la tuile 30TYP.*

## 4.2.2 Produits Sentinel-2

### 4.2.2.1 La mission Sentinel-2 : pour un suivi à haute résolution spatiale et temporelle des surfaces continentales

La mission Sentinel-2 (S2) s'inscrit dans le cadre du programme européen d'observation et de surveillance de la Terre, Copernicus. Initié en 2001 par l'ESA (European Space Agency) et l'Union Européenne, ce programme a pour objectif de rassembler et de générer de manière opérationnelle des produits de télédétection et in-situ permettant une étude globale de la planète. Dans ce contexte, les deux satellites Sentinel-2A (S2A) et Sentinel-2B (S2B) ont été lancés respectivement en juin 2015 et mars 2017. Situés sur une orbite héliosynchrone à 796 km d'altitude, ils fournissent des images multispectrales à haute résolution spatiale (décamétrique) et forte répétitivité temporelle (une image tous les dix jours, et tous les cinq jours considérant les deux satellites), et avec une large trace au sol (290 km). Ainsi, ils permettent de suivre précisément l'évolution de la végétation, de l'occupation des sols et la réponse aux changements climatiques. Diverses applications peuvent bénéficier de l'apport de ces satellites tels que le développement des cultures et des forêts, le suivi des pratiques agricoles ou encore la détection de catastrophes naturelles.

#### 4.2.2.2 Les bandes spectrales de l'imageur MSI

Chacun des satellites S2 emporte à son bord l'imageur multispectral MSI (Multi-Spectral Instrument; [Martimort et al., 2007](#)) qui permet une acquisition des reflectances de surface dans treize bandes spectrales. Celles-ci couvrent les domaines du visible (correspondant aux longueurs d'onde  $0.4 - 0.7 \mu\text{m}$ ), du proche infrarouge ( $0.8 - 1 \mu\text{m}$ ) et du moyen infrarouge ( $1 - 2.5 \mu\text{m}$ ). Les images fournies ont une résolution spatiale de 10 m, 20 m ou 60 m selon la bande utilisée (voir fig.4.6). Certaines bandes sont dédiées à la correction atmosphérique (B1, B9) ou à la détection de nuages (B10). Considérant l'impact non négligeable de l'atmosphère sur les reflectances, ces bandes constituent un atout majeur vis-à-vis des précédentes missions spatiales comme SPOT ou Landsat. De plus, grâce à la présence de ses deux satellites, la mission Sentinel-2 permet une couverture systématique de la surface terrestre, ce qui n'est pas le cas pour Landsat et SPOT qui ont une répétitivité temporelle supérieure à la quinzaine de jours (dans le cas de non-dépointage pour SPOT).





Figure 4.6 : Position spectrale et résolution spatiale des bandes Sentinel-2  
<https://www.cesbio.cnrs.fr/la-recherche/activites/missions-spatiales/sentinel-2/>

#### 4.2.2.3 La chaîne globale de prétraitement des produits optiques

Les données acquises par S2 sont récupérées par l'ESA et regroupées sous forme de tuiles correspondant à une surface au sol d'environ 100 x 100 km<sup>2</sup>. Plus exactement, ces tuiles correspondent à des images contenant 10980 x 10980 pixels pour les bandes à 10 m, et 5490 x 5490 pixels pour les bandes à 20 m. Les tuiles sont nommées selon un code spécifique défini par l'ESA qui dépend de leur position en latitude et longitude sur le globe (pour plus de détails sur la nomenclature des tuiles, voir [Gatti and Naud \(2017\)](#) ou <http://www.cesbio-ups-tlse.fr/multitemp/?p=5615>). Ces données constituent les images brutes, correspondant à des luminances ou radiances (cf. section 4.1.1.1) et appelées produits de niveau 1A selon la nomenclature définie par l'ESA et le CNES (Centre National d'Etudes Spatiales). Ces produits vont ensuite être prétraités pour permettre une utilisation opérationnelle par la communauté scientifique.

Tout d'abord, l'ESA réalise une correction géométrique, appelée orthorectification, afin de rendre chaque image superposable à une carte. L'image orthorectifiée (produit 1B, fig.4.7) est en quelque sorte l'image que le satellite aurait acquise si son angle d'observation se trouvait à la verticale (nadir) par rapport à la surface. Dans le cas de S2, les données sont projetées suivant le système de projection UTM/WGS84.

Ensuite, une correction radiométrique est effectuée. Cette étape permet de convertir les produits 1B correspondant à des luminances en produits de réflectance "Top Of Atmosphere" (nommés produits 1C, fig.4.7). Cette étape permet de s'affranchir de l'effet de l'éclairement solaire dans l'intensité lumineuse mesurée. Ainsi, cette dernière ne dépend que de la surface observée, et non des conditions d'illumination (pouvant varier au cours du temps).



**Figure 4.7 : Chaîne de prétraitement des produits optiques (Niv 1A à 2A). L'image présentée ici correspond à une acquisition faite le 06/06/2006 par le satellite SPOT-5 (d'après Lafrance et al., 2012).**

Ces prétraitements sont pris en charge par l'ESA, qui fournit des produits corrigés accessibles gratuitement aux utilisateurs via la Plateforme d'Exploitation des Produits Sentinelles (<https://peps.cnes.fr>) ou sur le site SciHub de Copernicus (<https://scihub.copernicus.eu>). De la même manière, le pôle thématique THEIA du CNES contribue à rassembler et distribuer

un ensemble de produits S2 bénéficiant en plus d'une correction atmosphérique réalisée au CNES via le segment sol MUSCATE (voir section 4.2.3 pour plus d'informations sur la chaîne de correction atmosphérique). Ces produits, de niveau 2A, correspondent à des réflectances "Top Of Canopy" corrigés des effets atmosphériques. Ils sont également fournis avec des produits informant sur la présence de nuages et de leur ombre, ainsi que sur la position dans l'image des surfaces en eau et de neige (<https://theia.cnes.fr>).

#### 4.2.2.4 Les produits de l'étude : réflectances et indices optiques

Dans cette étude, nous nous sommes intéressés plus particulièrement au comportement multi-échelle des réflectances acquises dans six bandes spectrales : les bandes du visible - le bleu B2 (0.50  $\mu m$ ), le vert B3 (0.56  $\mu m$ ), le rouge B4 (0.66  $\mu m$ ) - une bande du proche infrarouge B8 (0.84  $\mu m$ ) et les deux bandes du moyen infrarouge B11 (1.6  $\mu m$ ) et B12 (2.2  $\mu m$ ). **Ces bandes ont été choisies grâce à leur lien important avec les processus physiques et biophysiques des surfaces continentales** (section 4.1.1.1). En effet, de nombreux travaux ont montré l'intérêt du visible et du proche/moyen infrarouge pour mettre en évidence la variabilité des surfaces, à travers notamment l'étude de l'occupation du sol (Gutman et al., 2008; Huang et al., 2010; Lampkin and Yool, 2004). De plus, nous avons vu en section 4.1.2 que ce domaine spectral a déjà fait l'objet d'études visant à retranscrire les propriétés fractales (De Cola, 1989; Lam, 1990; Qiu et al., 1999) et multifractales (Alonso et al., 2017; Lovejoy et al., 2008b) des surfaces continentales.

En plus des réflectances de surface, nous avons également étudié deux indices optiques : le NDVI (Normalized Difference Vegetation Index ; Tucker and Sellers, 1986) et le NSMI (Normalized Soil Moisture Index ; Lampkin and Yool, 2004), qui rendent compte respectivement de l'état de la végétation et du niveau d'humidité du sol. **Ces variables sont fréquemment utilisées pour l'étude du fonctionnement des surfaces continentales, c'est pourquoi il nous a paru intéressant d'estimer ces indices pour en étudier leurs propriétés fractales.** Le NDVI est construit à partir des réflectances de surface ( $\rho$ ) dans les longueurs d'onde rouge (bande B4) et proche infrarouge (B8). Le NSMI est quant à lui obtenu depuis la combinaison des bandes du moyen infrarouge B11 et B12:

$$NDVI = \frac{\rho_{B8} - \rho_{B4}}{\rho_{B8} + \rho_{B4}} \quad 4.9$$

$$NSMI = \frac{\rho_{B11} - \rho_{B12}}{\rho_{B11} + \rho_{B12}} \quad 4.10$$

De plus, l'étude de ces indices nous servira à évaluer l'impact de la combinaison de réflectances de surfaces sur le comportement multi-échelle, et ce en comparant les propriétés fractales des bandes d'origine et celles de l'indice obtenu.

Enfin, ces réflectances de surface étant fournies à 10 m ou 20 m, nous pourrions ainsi observer si la résolution à laquelle sont définis les produits peut impacter le comportement multi-échelle. De même, cela nous permettra de voir si le fait de calculer un indice à 10 m (NDVI) ou 20 m (NSMI) peut également avoir un effet sur les propriétés d'échelle du produit final.

### 4.2.3 La chaîne de correction atmosphérique MAJA

#### 4.2.3.1 Description générale et intérêt

C'est avec le nombre croissant d'images satellites gratuitement disponibles que le développement de la chaîne MAJA (MACCS-ATCOR Joint Algorithm) a été initié en 2005 par le CESBIO et le CNES. L'objectif était de proposer un outil permettant la correction atmosphérique automatisée d'un grand nombre d'images utilisables en libre accès par la communauté.

MAJA est un processeur de niveau 2A qui a pour principales fonctions de corriger les effets atmosphériques liés aux gaz et aérosols, ainsi que de détecter les nuages et leurs ombres respectives. L'architecture principale se base sur l'algorithme MACCS (Multi-sensor Atmospheric Correction and Cloud Screening; Hagolle et al., 2015a; Lenoble et al., 2007; Rouquié et al., 2017). Ce dernier a été conjointement développé par le CESBIO, pour ce qui est des méthodes et de la version prototype, et par le CNES pour la version opérationnelle. Des modules de l'algorithme ATCOR (Atmospheric and Topographic Correction; Richter et al., 2006b), développé par le Centre Aérospatial Allemand (<https://www.dlr.de>), ont été ajoutés pour donner la version finale de MAJA. Celle-ci est fonctionnelle de manière opérationnelle au sein du centre de traitement MUSCATE du CNES, pour le compte du centre de données THEIA (<https://theia.cnes.fr>).

**Cette chaîne est originale de par son utilisation combinée de méthodes multispectrales et multi-temporelles, et de par le fait qu'elle soit dédiée aux séries temporelles d'images à haute résolution spatiale.** Jusqu'à ce jour, les données d'un certain nombre de satellites ont bénéficié des corrections de MAJA : Formosat-2, Landsat 5-7-8 (Hagolle et al., 2015a), SPOT 4-5 avec l'expérience Take-5 (Hagolle et al., 2015b; Navaro et al., 2016), Sentinel-2 (Baetens et al., 2019; Rouquié et al., 2017) et plus récemment le satellite Venus (Manivasagam et al., 2019). La caractéristique commune à ces satellites est qu'ils observent la Terre sous un angle de vue constant. Cette contrainte est nécessaire pour l'application de MAJA en raison de son utilisation importante de méthodes multi-temporelles.



#### 4.2.3.2 L'algorithme

Cette partie décrit les grandes étapes de la chaîne MAJA et leur articulation au sein du processeur (fig.4.8). Pour une description plus détaillée des bases théoriques sur lesquelles se fondent les modules du processeur, nous invitons le lecteur à se référer à Hagolle et al. (2017).

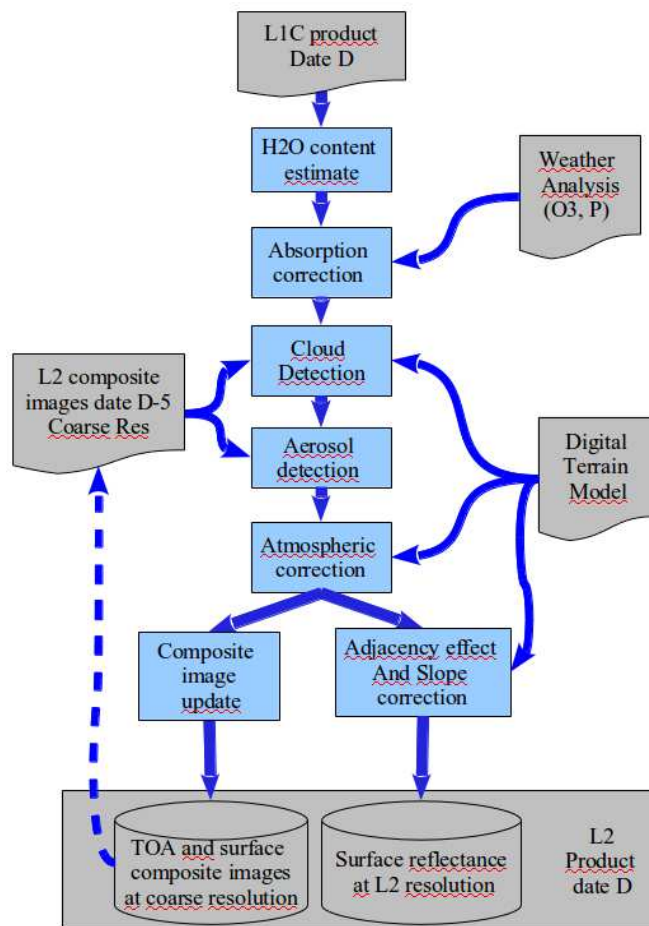



Figure 4.8 : Algorithme MAJA  
(<http://www.cesbio.ups-tlse.fr/multitemp>)

Tout d'abord, une première étape consiste à corriger les produits 1C (réflectances TOA) des effets d'absorption engendrés par les molécules de gaz (essentiellement de vapeur d'eau). Pour cela, il est nécessaire au préalable d'estimer la quantité de vapeur d'eau présente dans l'atmosphère au moment de l'acquisition. Certaines missions récentes comme S2 ou Venus disposent de bandes spectrales dédiées à l'estimation de la vapeur d'eau. Dans le cas de S2, il s'agit de la bande B9, située à la limite du proche infrarouge ( $0.95 \mu\text{m}$ ). Les satellites multispectraux ne disposant pas de ces bandes, tels que Landsat ou Formosat, ont recours à des données annexes issues d'analyses météorologiques. Une fois le contenu en eau estimé, la correction des réflectances est appliquée au moyen du modèle analytique SMAC (Simplified Method for Atmospheric Correction; Rahman and Dedieu, 1994). Ce dernier se base sur une




formulation simplifiée des équations de transfert radiatif décrivant les interactions des rayons solaires avec les différents constituants de l'atmosphère (cf. section 4.1.3.2). De manière plus concrète, à chaque bande spectrale du capteur est affecté un coefficient particulier qui va plus ou moins corriger le signal en fonction de la longueur d'onde d'acquisition.

La seconde étape concerne la détection de nuages (et ombres) décrite dans [Hagolle et al. \(2010\)](#). La méthode, appelée Multi-Temporal Cloud Detection (MTCD), se base essentiellement sur des approches multi-temporelles. Plusieurs tests sont réalisés pour vérifier si un pixel contient ou non un nuage. Ici, nous nous limiterons à la description de deux tests principaux (pour les autres tests, les plus utilisés dans la littérature sont cités en section 4.1.3.2). Le premier test se base sur deux propriétés essentielles qui distinguent les nuages de la surface : leur forte réflectance dans le bleu, et leur dynamique temporelle. Ainsi, l'apparition d'un nuage dans l'image se traduira par une forte augmentation de la réflectance dans le bleu. Un autre test complète l'approche précédente de manière à détecter les nuages hauts et fins, plus précisément les cirrus. Souvent créés par le passage des avions, ces nuages sont très fins et par conséquent difficiles à détecter par la première méthode. Pour réaliser cette détection, l'algorithme utilise l'information acquise par le capteur autour des  $1.38 \mu m$  (bande B10 pour S2). A cette longueur d'onde, presque l'intégralité des rayons solaires réfléchis par la surface est absorbée par la vapeur d'eau contenue dans les basses couches de l'atmosphère. Ainsi, si un signal parvient au capteur du satellite, il est fort probable qu'il soit dû à la présence d'un nuage situé à haute altitude, c'est-à-dire autour des 3000 mètres ([Gao and Kaufman, 1995](#)). La figure 4.9 ci-dessous présente un exemple d'image Landsat-8 acquise sur Paris dans le visible d'une part (gauche) et à la longueur d'onde  $1.38 \mu m$  d'autre part (droite). Nous constatons que les cirrus générés par le passage des avions sont facilement détectables sur l'image de droite.



*Figure 4.9 : Image Landsat-8 acquise le 03/04/2013 sur Paris : en composition colorée à partir des bandes "rouge-vert-bleu" à gauche, et dans le canal  $1.38 \mu m$  à droite (d'après [Hagolle et al., 2017](#)).*

Une fois les nuages détectés, une phase consacrée à la détection de leur ombre est ensuite traitée par l’algorithme. Cette étape suit la méthode proposée par [Hégarat-Mascle and André \(2009\)](#) dans laquelle plusieurs tests sont réalisés qui sont fondés sur des propriétés spectrales (ombres assimilées à des zones sombres dans l’image), géométriques (même forme entre ombre et nuage) et temporelles (apparition et disparition subite, comme pour les nuages). Un exemple de détection de nuages et d’ombre réalisée par MAJA est présenté en figure 4.10 : il s’agit ici d’une image acquise sur le Maroc par le satellite Formosat-2.



*Figure 4.10 : Composition colorée des réflectances TOA acquises dans le bleu, vert et rouge par le satellite Formosat-2, sur le Maroc, le 13/04/2006. Les nuages détectés par la méthode MTCD sont entourés en blancs, et les ombres correspondantes sont entourées en noir (d’après [Hagolle et al., 2017](#)).*


Une deuxième correction atmosphérique est réalisée de manière à supprimer les effets de diffusion des aérosols sur les mesures de réflectance. Dans un premier temps, l’épaisseur optique d’aérosols – appelée AOT (Aerosol Optical Thickness) – est estimée par application d’une fonction de coût globale fondée sur des critères multi-temporels et multispectraux ([Hagolle et al., 2015a](#)). Le critère multi-temporel se base sur la stabilité relative des surfaces comparé aux aérosols qui vont varier et se déplacer rapidement ([Hagolle et al., 2008](#)). Ainsi, la différence dans les mesures de réflectances acquises pour deux images consécutives est liée à une variation d’AOT, qui peut donc être estimée. Ensuite, le critère multispectral se base sur la relation empirique obtenue entre les réflectances acquises dans le bleu et le rouge sur une surface correspondant à de la végétation dense ([Kaufman and Sendra, 1988](#)). Dans le cas de S2, l’équation empirique suivante a été estimée à partir de plusieurs images acquises sur

des zones à forte végétation, et dont la couverture nuageuse et le taux d'aérosol étaient connus comme étant faibles voire nuls (Hagolle et al., 2015a; Rouquié et al., 2017) :

$$\rho_{B2} = 0.45 \times \rho_{B4}$$

4.11


La fonction de coût de l'algorithme va donc chercher la valeur d'AOT qui minimise la différence entre la réflectance dans le bleu obtenue après correction atmosphérique et la réflectance prédite par la bande B4 (Eq.4.11). Cette correction est en fait réalisée à chaque itération où la fonction de coût est évaluée, et ce à partir de tables LUT (Look Up Tables) qui associent à chaque type d'aérosol un modèle particulier de correction. Ces modèles ont été générés depuis le code de transfert radiatif SOS (Successive Orders of Scattering; Lenoble et al., 2007). A cette étape se rajoute également une phase de correction des effets de diffusion liés aux molécules de gaz. Cette correction se base aussi sur ces tables LUT, et a l'avantage d'être plus simple d'application étant donnée l'homogénéité de distribution des molécules d'air dans l'atmosphère (contrairement aux aérosols qui nécessitent une approche multi-temporelle pour les détecter). En figure 4.11 nous pouvons observer une image Landsat-8 (gauche) pour laquelle l'épaisseur optique d'aérosols a été estimée par MAJA (droite).



*Figure 4.11 : Composition colorée des réflectances TOA acquises par Landsat-8 aux Etats-Unis (gauche), et l'épaisseur optique d'aérosol correspondante estimée par MAJA (droite). Cette épaisseur étant un rapport entre rayonnements incidents et rayonnements affectés par les aérosols, celle-ci s'exprime sans unité (d'après Hagolle et al., 2017).*

Enfin, une dernière étape consiste à prendre en compte deux types d'effets qui peuvent impacter le signal mesuré : les effets dits de "voisinage" (ou de proximité) et les effets de pente. Tout d'abord, lorsque le satellite mesure le rayonnement réfléchi par une cible au sol (correspondant à un pixel dans l'image par exemple), la réflectance de surface totale acquise par le capteur comprend principalement les réflectances de trois types d'éléments de

la scène étudiée. D'après la figure 4.12, cette réflectance totale mesurée est en fait la combinaison de la réflectance de la cible  $\rho_t$  (signal d'intérêt) correspondant à la trajectoire 2 sur le schéma, de la réflectance propre de l'atmosphère  $\rho_a$  (trajectoire 1) et également des réflectances  $\rho_b$  d'autres points au sol situés autour de la cible (pixels voisins) engendrant les trajectoires 3 et 4. Ces effets de voisinage sont dus aux aérosols qui dévient les signaux réfléchis et les mélangent aux signaux originaux (non impactés). Afin de corriger cet artefact, pour chaque pixel de l'image la chaîne MAJA retranche à la réflectance totale la réflectance liée aux effets de voisinage (soit  $\rho_b$ ). Cette dernière est estimée en moyennant la réflectance totale, et ce en utilisant un filtre gaussien pondéré par la distance à la cible (filtre de convolution de rayon 2 km centré sur le pixel d'intérêt). Cette méthode est une forte approximation des effets de voisinage car il faudrait en réalité prendre en compte dans le calcul certaines variables comme l'AOT, le modèle d'aérosols ou encore la longueur d'onde d'acquisition. Tout de même, la méthode a été appliquée et testée dans MAJA sur plusieurs images successives correspondant à diverses quantités d'AOT, révélant une amélioration des performances après correction des effets de voisinage (Hagolle et al., 2017). Ensuite, le relief de la zone observée par le satellite peut avoir un impact sur les conditions d'illumination et par conséquent modifier la réflectance mesurée. En effet, l'intensité lumineuse réfléchie par le sol varie selon la pente. Si cette dernière est perpendiculaire à la direction des rayonnements solaires, la réflectance sera élevée, alors que si la pente est parallèle, la réflectance sera nulle. La chaîne MAJA prend en compte ces effets d'illumination en intégrant le modèle numérique de terrain SRTM (Shuttle Radar Topography Mission; Farr et al., 2007) et calcule une réflectance de surface qui correspondrait à celle observée dans le cas d'une surface horizontale.



**Figure 4.12 : Schéma récapitulatif des différents trajets des rayonnements solaires contribuant à la réflectance TOA mesurée par le capteur satellite (d'après Richter, 2006a).**



#### 4.2.4 Prétraitements réalisés sur les images provenant de THEIA


Dans les sections précédentes nous avons présenté les différents prétraitements appliqués sur les produits S2 par l'ESA et le CNES/THEIA pour fournir des données utilisables de manière opérationnelle par la communauté. Ici sont décrits les prétraitements que j'ai moi-même réalisés sur les produits THEIA (niveau 2A) afin de pouvoir appliquer les outils d'analyse multifractale de manière pertinente (selon la méthode décrite en section 2.3.3).

Nous avons vu précédemment que les nuages avaient un impact non négligeable sur les reflectances de surface et leurs propriétés fractales. **Ainsi, nous avons fait attention de sélectionner des images pour lesquelles la couverture nuageuse était faible.** Les tuiles S2 contenant un nombre relativement important de pixels (10980 x 10980 au maximum), nous nous sommes permis de restreindre la taille de nos images de manière à identifier une zone qui présente au maximum 20% de nuages au cours de la période d'étude. Ainsi, nous avons pu choisir des sous-images de taille 4096 x 4096 pixels pour les bandes du visible (voir fig.4.13), celle du proche infrarouge et le NDVI, et les sous-images correspondantes de 2048 x 2048 pixels pour les bandes du moyen infrarouge et le NSMI. **Cette phase d'identification des nuages a été possible grâce au masque de nuage fourni par THEIA.** Contrairement aux données MODIS (section 3.2.6), les produits S2-MAJA ne sont pas filtrés des pixels nuageux. Nous avons donc remplacé chacun de ces pixels par des données manquantes (NaN), qui ont ensuite été interpolées sur l'ensemble de l'image par interpolation bilinéaire.



*Figure 4.13 : Composition colorée des réflectances TOA (d'après bandes du visible) acquises le 10/07/2016 sur notre zone d'étude (département du Gers – tuile 30TYP).*

Au final, 15 dates ont été sélectionnées entre janvier et décembre 2016. Celles-ci sont représentées sur le chronogramme de la figure 4.14, où nous constatons une répartition des dates qui couvre toutes les saisons, avec tout de même un nombre plus important de sous-images en été. Sur les 15 sous-images, nous estimons une couverture nuageuse moyenne de 2% sur la période, avec seulement 4 dates ayant plus de 2% de nuages – la plus grande couverture nuageuse étant obtenue le 23 juin avec 12.5%. Aucune donnée manquante autre que celle liée aux nuages n’a été observée dans la zone sélectionnée. Ainsi, le pourcentage final de données manquantes (et interpolées) sur l’ensemble des sous-images S2 reste très faible ( $\sim 2\%$ ), rendant son impact possible sur l’analyse multi-échelle négligeable par comparaison par exemple aux produits DisPATCH du chapitre précédent.



**Figure 4.14 :** *Chronogramme des acquisitions Sentinel-2A sélectionnées durant la période Janvier-Décembre 2016.*

Dans cette partie, nous venons de voir que la région Sud-Ouest possédait des caractéristiques intéressantes pour l’étude du comportement multi-échelle de ses surfaces. En effet, ces dernières sont définies par une hétérogénéité spatiale importante causée par des facteurs anthropogéniques comme l’agriculture. Grâce aux produits Sentinel-2 fournis et traités par l’ESA, nous pouvons réaliser un suivi régulier et détaillé de ces surfaces. De plus, nous avons vu que la chaîne de traitement MAJA était un atout majeur dans notre étude du comportement multi-échelle des surfaces continentales, assurant des produits corrigés des effets atmosphériques.

## 4.3 Résultats

Dans cette partie, nous présentons les résultats obtenus après analyse multi-échelle des produits S2 décrits précédemment. Une première sous-partie sera consacrée au comportement multi-échelle moyen sur l'ensemble de la période d'étude (cf. section 2.3.3), puis une deuxième sous-partie s'intéressera à la dynamique temporelle des propriétés d'échelle.


### 4.3.1 Comportement multi-échelle moyen : mise en évidence des régimes d'échelle et impact de la longueur d'onde

Afin de déterminer au préalable les différents régimes et comportements d'échelle de nos produits, nous avons calculé la moyenne de chacun des estimateurs statistiques obtenus sur les 15 dates retenues entre janvier et décembre 2016. Les figures 4.15-17 représentent respectivement les estimateurs multi-échelles moyens des spectres de puissance, fonctions de structure de Haar et moments statistiques.

#### 4.3.1.1 Identification des gammes d'échelles

D'après les spectres moyens de la figure 4.15, nous pouvons remarquer qu'un comportement en deux gammes d'échelles semble caractériser les différents produits, ce qui peut se voir également sur les fonctions de structure et moments statistiques présentés plus loin (fig.4.16-17). A première vue, une zone de transition, voire une rupture séparant les deux régimes pourrait se situer entre la centaine de mètres et le kilomètre. Par commodité, nous appellerons par la suite cette rupture "R1". De plus, dans le cas particulier des spectres de puissances, nous constatons qu'une deuxième rupture d'échelle (R2) semble présente vers les fines échelles. Pour vérifier cela et déterminer de manière objective la position de ces ruptures, j'ai appliqué l'algorithme de segmentation de [D'Errico \(2017\)](#) à chacun des estimateurs statistiques et pour chaque produit, en suivant la méthodologie décrite en Annexe C : le paramètre d'entrée de l'algorithme correspondant au nombre de ruptures à détecter a été fixé à 1 pour les fonctions de structure et les moments, et à 2 pour les spectres. Le tableau 4.2 récapitule la position des ruptures estimées après segmentation des différentes courbes. En considérant l'ensemble des produits (bandes et indices confondus), les spectres et les moments présentent en moyenne une rupture R1 commune qui se situe vers les 400 m. Les deux fonctions de structures – obtenues pour les axes X et Y de l'image – sont caractérisées par des ruptures R1 positionnées à des échelles légèrement plus grandes, surtout en ce qui concerne l'axe Y (~ 600 m).





*Figure 4.15 : Spectres de puissance moyens estimés à partir des bandes et indices Sentinel-2, pour la période Janvier-Décembre 2016.*

	Grid spacing (m)	SPECTRA		STRUCT X	STRUCT Y	MOMENTS
		R1 (m)	R2 (m)	R1 (m)	R1 (m)	R1 (m)
<b>B2</b>	10	420	37	580	580	360
<b>B3</b>		390	37	510	570	300
<b>B4</b>		390	39	540	570	360
<b>B8</b>		290	37	480	510	320
<b>NDVI</b>		380	48	580	570	340
<b>B11</b>	20	320	75	460	550	370
<b>B12</b>		370	75	550	580	390
<b>NSMI</b>		420	-	700	690	430

*Tableau 4.2 : Positions des ruptures d'échelle R1 (et R2 dans le cas des spectres) estimées par segmentation selon [D'Errico \(2017\)](#) pour chaque produit et chaque estimateur statistique moyen.*

Pour ce qui est de la rupture *fine échelle*  $R2$  observée sur les courbes des spectres, elle semble se situer autour des 40 m pour les produits dont la résolution est à 10 m, c'est-à-dire les bandes du visible (B2, B3, B4), la bande du proche infrarouge (B8) et l'indice de végétation NDVI. Dans le cas des produits à 20 m, cette rupture se décale vers des échelles plus grandes (75 m) pour les bandes du moyen infrarouge B11 et B12, voire même disparaît en ce qui concerne l'indice d'humidité NSMI (spectre plat pour les fines échelles). Si l'on analyse plus en détails ce dernier spectre, on peut même constater une remontée de la courbe vers les points situés aux plus fines échelles ( $\sim 50$  m). Ce phénomène traduit la présence de bruit dans les données NSMI qui affecte les plus hautes fréquences de l'image, créant artificiellement un surplus d'énergie aux *fines échelles*. Comme les bandes B11 et B12, à partir desquelles le NSMI a été estimé, ne présentent pas de remontée de leurs spectres aux *fines échelles*, il se pourrait que leur combinaison soit à l'origine du bruit observé sur l'indice d'humidité. De même, nous constatons que le NDVI présente une rupture *fine échelle* (48 m) moins prononcée que pour les bandes B3 et B8 l'ayant généré, avec une légère remontée du spectre pour les derniers points ( $\sim 20$  m). Bien que le phénomène soit bien moins prononcé que pour le NSMI, l'indice de végétation paraît également impacté par la combinaison de bandes.

**De manière générale, l'algorithme de segmentation semble confirmer la présence de deux régimes d'échelle pour chaque produit analysé, avec une transition moyenne située autour des 450 m.** Cette rupture semble tout de même varier dans un intervalle compris entre 300 m et 700 m en fonction des produits ou des estimateurs. Nous pouvons noter que la rupture d'échelle  $R1$  détectée sur B8 se positionne à des échelles plus fines ( $\sim 400$  m en moyenne) que pour les autres produits. A l'opposée, le NSMI présente une rupture  $R1$  située vers des échelles plus grandes ( $\sim 700$  m). De plus, bien qu'elle soit présente que sur les spectres de puissance, la rupture  $R2$  semble récurrente d'un produit à l'autre (excepté pour le NSMI). L'origine de cette rupture sera discutée en section 4.4.1.

#### 4.3.1.2 Estimation et comparaison des exposants d'échelle moyens

D'après les ruptures  $R1$  et  $R2$  détectées précédemment, nous allons à présent nous intéresser aux propriétés d'échelle de nos produits en considérant les deux gammes suivantes : la gamme *large échelle* (que nous appellerons *gamme I*) correspondant à des échelles supérieures à 1 km ( $l > R1$ ), et la gamme *fine échelle* (*gamme II*) pour des échelles inférieures à 400 m mais n'incluant pas, dans le cas des spectres, les échelles proches de la résolution maximale du capteur ( $R1 > l > R2$ ). Nous avons délibérément sélectionné deux gammes qui ne se suivent pas directement de manière à éviter la zone de transition entre les deux régimes qui est assez large et qui peut varier en fonction des produits ou des estimateurs utilisés. Ainsi, pour chacune de ces gammes, j'ai estimé les paramètres d'échelle suivant les méthodes décrites en section 2.3.2. Notons que les gammes d'échelle sur lesquelles ont été réalisées les régressions linéaires peuvent être sensiblement différentes selon le type de

produit analysé (bandes ou indices, définis à 10 m ou 20 m) et l'estimateur utilisé. En particulier, une troisième gamme d'échelles (*gamme III*) sera utilisée pour analyser le comportement des spectres de puissances pour les échelles situées en dessous de la rupture  $R2$  (section 4.4.1). Une description détaillée des limites supérieures et inférieures de chaque gamme utilisée pour les différents produits est donnée en Annexe H.

Pour ce qui est des spectres de puissances (fig.4.15), nous constatons que les deux régimes d'échelle se distinguent par des pentes relativement faibles sur la *gamme I* et à l'inverse plutôt prononcées sur la *gamme II*. En effet, pour  $l > 1$  km nous identifions sur l'ensemble des produits un exposant  $\beta$  dont la valeur moyenne vaut 0.3 (tableau 4.3.a). Ainsi, pour ces *larges échelles*, l'analyse spectrale semble montrer que les produits S2 ont un comportement qui tend à se rapprocher de celui d'un bruit décorrélié (cas d'une pente nulle). Ces résultats sont en contradiction avec les travaux de [Lovejoy et al. \(2008b\)](#) qui ont identifié des pentes supérieures à 1 ( $\beta = 1.17 \pm 0.08$ ) sur une gamme d'échelles similaire (500 m – 25 km), à partir de réflectances acquises dans des bandes spectrales comparables (capteur MODIS). De même, nos résultats ne sont pas non plus comparables à ceux d'[Alonso et al. \(2017\)](#) qui n'ont observé qu'une seule loi d'échelle sur la gamme (120 m – 15 km), pour des réflectances issues de bandes similaires (satellites Ikonos et Landsat-7). Cependant, l'étude d'[Alonso et al. \(2017\)](#) étant basée sur l'application d'un formalisme différent d'analyse multifractale (cf. section 4.1.2), il est donc difficile de comparer directement nos pentes spectrales à leurs résultats. Néanmoins, ces derniers ont effectivement montré la présence de propriétés multifractales sur cette gamme d'échelles. Ainsi, les différences entre nos résultats et ceux de [Lovejoy et al. \(2008b\)](#) et d'[Alonso et al. \(2017\)](#) pourraient être liées à des spécificités géographiques (centre de l'Espagne dans leurs cas), aux caractéristiques des capteurs (largeur et position précise des bandes), ou encore au fait que leurs analyses ait été réalisées sur une ou deux dates particulières, ne permettant pas d'acquérir le comportement multi-échelle moyenné sur une période comme nous avons pu le faire. Cependant, ces différences de pentes spectrales (notamment par comparaison avec [Lovejoy et al., 2008b](#)) paraissent trop importantes pour qu'elles soient simplement dues au capteur. Ainsi, ces écarts significatifs seraient plus vraisemblablement engendrés par la différence entre les signaux physiques mesurés, et donc directement liés à la région d'étude ou à l'aspect mono ou multi-temporel de l'analyse. Si l'on compare les pentes spectrales des différents produits, la *gamme I* ne semble pas présenter de différences significatives au sein des bandes et indices étudiés ( $0.2 < \beta < 0.3$  d'après le tableau 4.3.a).

(a)	Grid spacing	Scale range	$\beta$	$R^2_\beta$	$\alpha$	$C_1$	$R^2_{K(q)}$	H	$R^2_H$
B2	10 m	$l > 1 \text{ km}$	0,30	0,62	1,96	0,007	0,89	-0,27	0,98
B3			0,31	0,64	1,86	0,006	0,91	-0,28	0,99
B4			0,24	0,55	1,81	0,007	0,92	-0,30	0,99
B8			0,29	0,60	1,80	0,004	0,89	-0,27	0,99
NDVI			0,20	0,50	1,91	0,005	0,88	-0,31	0,99
B11	20 m	$l > 1 \text{ km}$	0,28	0,56	1,83	0,004	0,87	-0,29	0,99
B12			0,25	0,53	1,81	0,005	0,88	-0,29	0,99
NSMI			0,22	0,55	2,23	0,005	0,83	-0,29	0,99

(b)	Grid spacing	Scale range	$\beta$	$R^2_\beta$	$\alpha$	$C_1$	$R^2_{K(q)}$	H	$R^2_H$
B2	10 m	$l < 400 \text{ m}$	1,63	0,99	1,97	0,11	0,96	0,32	0,98
B3			1,67	0,99	1,78	0,11	0,96	0,32	0,98
B4			1,76	0,99	1,56	0,12	0,96	0,35	0,97
B8			1,37	0,98	1,53	0,09	0,96	0,23	0,93
NDVI			1,84	0,99	1,61	0,13	0,96	0,37	0,98
B11	20 m	$l < 400 \text{ m}$	1,96	0,97	1,53	0,11	0,97	0,35	0,95
B12			1,96	0,98	1,53	0,12	0,96	0,37	0,97
NSMI			1,81	0,98	1,97	0,11	0,96	0,35	0,98

**Tableau 4.3 : Paramètres multi-échelles issus de l'analyse multifractale sur les gammes I(a) et II(b) des produits Sentinel-2, pour la période Janvier-Décembre 2016. Les valeurs de  $\beta$ ,  $\alpha$ ,  $C_1$  et H ont été obtenues à partir des régressions linéaires appliquées sur les estimateurs statistiques moyens. En revanche, les coefficients de détermination  $R^2$  présentés ici correspondent à la moyenne de l'ensemble des coefficients obtenus pour chaque date. Notons que  $R^2_{K(q)}$  correspond à la moyenne des coefficients obtenus pour chaque courbe de moments. De même, H est obtenu à partir de la moyenne des paramètres  $H_x$  et  $H_y$ , ainsi que  $R^2_H$  à partir de  $R^2_{Hx}$  et  $R^2_{Hy}$ .**

Si l'on s'intéresse maintenant aux *fin*es échelles (*gamme II*), les produits présentent des valeurs de pente spectrale plus élevées et situées entre 1.4 et 2. **Cela révèle un signal davantage autocorrélé, avec une variabilité qui augmente avec la distance au sein de la *gamme II*.** De plus, contrairement au régime *large échelle*, cette gamme montre des comportements assez différents d'un produit (ou d'une longueur d'onde d'acquisition) à l'autre, que nous avons classés en trois catégories :

- $\beta \approx 1.4$  : réflectances du proche infrarouge

Sur cette gamme, la plus faible valeur de pente spectrale est obtenue pour les réflectances acquises dans le proche infrarouge par la bande B8. Des valeurs comparables ont été trouvées sur des données également acquises dans le domaine du proche infrarouge, mais correspondant à des nuages (Lovejoy and Schertzer, 2006).

- $\beta \approx 1.6 - 1.8$  : réflectances du visible et indices optiques

Les trois bandes du visible (B2, B3, B4) et les deux indices (NDVI, NSMI) présentent des pentes très proches de la valeur théorique  $5/3$  définie par Kolmogorov. Cette pente spectrale, associée à une intégration fractionnaire  $H = 1/3$ , a souvent été retrouvée en turbulence, notamment via l'analyse multi-échelle de variables atmosphériques telles que des incréments de vitesse (Schmitt et al., 1993) ou des données de précipitation (Lovejoy and Schertzer, 2008). Nous pouvons également noter que la pente spectrale semble augmenter avec la longueur d'onde pour des réflectances acquises dans le visible (cf. tableau 4.3.a).

- $\beta \approx 2$  : réflectances du moyen infrarouge

Les bandes B11 et B12 présentent des valeurs élevées de pente spectrale, comparables à celles obtenues dans certaines études de la topographie (Gagnon et al., 2006).

De plus, si l'on compare les indices avec les bandes à partir desquelles ils ont été estimés, ces résultats tendent à montrer que pour les *fines échelles (gamme II)* l'indice de végétation suit un comportement spectral moyen comparable à la bande B4 mais différent de la bande B8. En revanche, l'indice d'humidité présente une pente spectrale proche de celles obtenues pour les deux bandes B11 et B12. Une autre remarque générale sur les spectres peut être faite sur la qualité de la loi d'échelle qui se trouve très bonne sur la *gamme II*, tout produit confondu ( $R^2 \approx 0.98$ ), alors qu'elle diminue fortement sur la *gamme I* ( $R^2 \approx 0.6$ ). Cela peut en partie s'expliquer par l'échantillonnage des spectres de puissance qui est moins important sur les basses fréquences (grandes échelles) que sur les hautes fréquences (fines échelles).

Cette première étape d'analyse spectrale permet d'anticiper les résultats relatifs aux fonctions de structure de Haar (fig.4.16), en particulier sur le caractère non-conservatif (cf. section 2.2.3) de nos produits. En théorie, des paramètres  $\beta$  supérieur et inférieur à 1 correspondent respectivement à des paramètres  $H$  supérieur et inférieur à 0 (Eq.2.18). Ce comportement est en effet confirmé par l'allure des fonctions de structure qui présentent des pentes non nulles dans les deux gammes. De plus, ces deux gammes se différencient bien par une pente positive au niveau des *fines échelles* ( $H \approx 0.3$  sur la *gamme II*) – correspondant à des fluctuations croissantes du signal avec l'échelle spatiale – et une pente négative pour les *larges échelles* ( $H \approx -0.3$  sur la *gamme I*) – correspondant à des fluctuations décroissantes. Ainsi, il semblerait que la zone de transition entre ces deux régimes se situe à des échelles où l'on obtient le maximum de fluctuations présentes au sein de nos produits (ce point sera discuté dans la section 4.4.2). Nous pouvons également noter que les fonctions de structures de chaque axe X et Y de l'image (courbes de même couleur) ont des allures comparables pour un même produit. Cela signifie que les réflectances et indices étudiés présentent un comportement globalement isotrope si l'on considère l'ensemble de la période d'étude.




Figure 4.16 : Fonctions de structure de Haar moyennes estimées à partir des bandes et indices Sentinel-2, pour la période Janvier-Décembre 2016.

Contrairement à l'analyse spectrale, les valeurs des paramètres  $H$  (toute gamme confondue) présentent des valeurs assez proches entre les produits (tableau 4.3). Sur la *gamme II*, les valeurs sont comparables à la valeur théorique  $H = 1/3$  de la turbulence, confirmant les résultats obtenus par analyse spectrale pour les réflectances du visible et les indices optiques. Pour la *gamme I*, nous trouvons des valeurs opposées ( $H = -1/3$ ), qui ont été rarement trouvées dans la littérature. En effet, les quelques études qui ont mis en évidence des processus non-conservatifs caractérisés par des valeurs de  $H$  négatives ont été réalisées sur des séries temporelles de températures de surface (Lovejoy and Schertzer, 2012a, 2012b), pour des échelles comprises entre la dizaine de jours et la dizaine d'années, et ce à partir du même type de fonctions de structure que nous utilisons (ondelettes de Haar). Enfin, nous remarquons tout de même que la bande B8 se différencie des autres produits. Celle-ci semble présenter les pentes les moins pentues (valeurs absolues de  $H$  les plus petites) sur les deux gammes d'échelles. Ce phénomène est cependant un peu plus accentué sur la *gamme II*, ce qui confirme les résultats de l'analyse spectrale.



Enfin, les moments statistiques ont été estimés pour des ordres  $q$  compris entre 0 et 3 par pas de 0.1, selon la méthode décrite en section 2.3.2.3. Les moments statistiques moyens obtenus pour nos différents produits S2 sont présentés en figure 4.17. Les fonctions d'échelle  $K(q)$  correspondantes ont été directement calculées à partir des moments moyens, sur chacune des deux gammes (fig.4.18). Grâce à ces fonctions, nous avons estimé les paramètres universels  $\alpha$  et  $C_1$  pour les deux régimes d'échelles. Pour rappel, ces paramètres ont été obtenus en appliquant une méthode de minimisation entre la fonction d'échelle empirique et la forme du modèle décrite par l'équation 2.11.

Concernant le paramètre  $\alpha$ , nous obtenons de manière générale des valeurs comprises entre 1.5 et 2.2 (tableau 4.3). Ces résultats sont comparables à ceux trouvés habituellement en turbulence et topographie ( $\alpha = 1.9 - 2$  ; [Lovejoy and Schertzer, 2010c](#); [Gagnon et al., 2006](#)), ou pour des données de précipitations et nuages ( $\alpha = 1.5$  ; [Tessier et al., 1993](#)). Nous constatons que nos valeurs sont légèrement plus élevées sur la *gamme I* (droites de régression en rouge, fig.4.17) que sur la *gamme II* (droites en vert), surtout pour les réflectances correspondant aux longueurs d'ondes les plus grandes (B4, B8, B11, B12). En effet, pour ces bandes, la valeur de  $\alpha$  varie en moyenne de 1.8 à 1.5 lorsque que l'on se situe à *large* ou *fine* échelle. En revanche, pour ce qui est des réflectances à plus faibles longueurs d'onde (B2, B3), la gamme d'échelles semble avoir très peu d'impact sur la valeur de  $\alpha$ . Sur chacune des gammes, il apparaît que plus la longueur d'onde d'acquisition est élevée, plus l'indice de multifractalité diminue. Ces résultats sont en accord avec ceux trouvés par [Lovejoy et al. \(2008b\)](#), qui ont observé le même lien entre bandes spectrales et paramètre  $\alpha$  sur la gamme [500 m – 25 km]. Pour ce qui est des indices optiques, les deux produits présentent également des valeurs de  $\alpha$  plus importantes sur la *gamme I* que sur la *gamme II*. Dans l'ensemble, l'indice de végétation suit un comportement multi-échelle moyen comparable aux bandes B3 et B4 à partir desquelles il a été estimé. L'indice d'humidité présente en revanche, pour les deux régimes, un indice  $\alpha$  élevé ( $> 2$ ) et plus important que les bandes B11 et B12. [Lovejoy et al. \(2008b\)](#) ont également observé ces fortes valeurs pour le NSMI ( $\alpha \approx 2.3$ ). Notons que ces estimations de  $\alpha$  supérieures à 2 ne peuvent pas convenir puisque ce paramètre est compris théoriquement entre 0 et 2 (cf. section 2.2.3).

Si l'on s'intéresse maintenant au paramètre  $C_1$ , nous constatons que celui-ci présente des valeurs beaucoup plus faibles sur la *gamme I* que sur la *gamme II* (plus d'un facteur 10). En effet, pour  $l < 400$  m, nous trouvons  $C_1 \approx 0.1$ , ce qui est globalement similaire à ce qui a pu être obtenu dans d'autres études en géophysique ([Lavallée et al., 1993](#); [Tessier et al., 1993](#); [Lovejoy and Schertzer, 2010c](#); [Gagnon et al., 2006](#)). En revanche, pour  $l > 1$  km, nos valeurs de  $C_1$  sont inférieures à 0.01. Cela traduit une dispersion du signal qui est bien plus importante à *fine* échelle qu'à *large* échelle. Ce phénomène peut s'observer sur les courbes des fonctions d'échelle  $K(q)$  (fig.4.18) qui ont une variabilité plus étendue pour les *fin*es échelles ( $-0.2 < K(q) < 0.8$  sur la *gamme II*) que pour les *large*s échelles ( $-0.01 < K(q) < 0.05$  sur la

*gamme I*). Des résultats équivalents ont été obtenus par [Lovejoy et al. \(2008b\)](#), avec des valeurs de  $C_1 \approx 0.04$  pour des bandes spectrales comparables aux nôtres. De plus, nous constatons qu’au sein d’une même gamme d’échelles (*I* ou *II*), tous nos produits (bandes et indices confondus) sont caractérisés par des valeurs de  $C_1$  assez similaires. Ainsi, la longueur d’onde d’acquisition des réflectances ne semble pas impacter significativement nos valeurs de  $C_1$ . Cependant, nous pouvons tout de même remarquer que la bande B8 se distingue légèrement des autres produits. En effet, celle-ci présente les valeurs les plus faibles à la fois pour les *fines échelles* ( $C_1 = 0.09$ ) et les *grandes échelles* ( $C_1 = 0.004$ ). Pour la *gamme II*, on constate que la fonction  $K(q)$  de B8 se différencie des autres bandes et des indices, surtout pour les ordres élevés ( $q > 2$ ). Enfin, nous pouvons observer sur l’ensemble des produits que la qualité de la loi d’échelle est plus faible pour  $l > 1$  km ( $R_{K(q)}^2 \approx 0.88$ ) que pour  $l < 400$  m ( $R_{K(q)}^2 \approx 0.96$ ). [Lovejoy et al. \(2008b\)](#) ont détecté le même type de comportement sur les moments statistiques. Selon eux, cela serait dû aux faibles tailles d’échantillons statistiques disponibles à grandes échelles – ce qui est lié au nombre réduit de pixels dans l’image lorsque l’on se rapproche de l’échelle maximale. Une autre explication possible serait liée à l’algorithme de correction atmosphérique qui peut altérer les basses fréquences en agissant comme un filtre passe-bas – s’assurant que l’énergie dans l’ensemble de la scène observée soit approximativement constante.

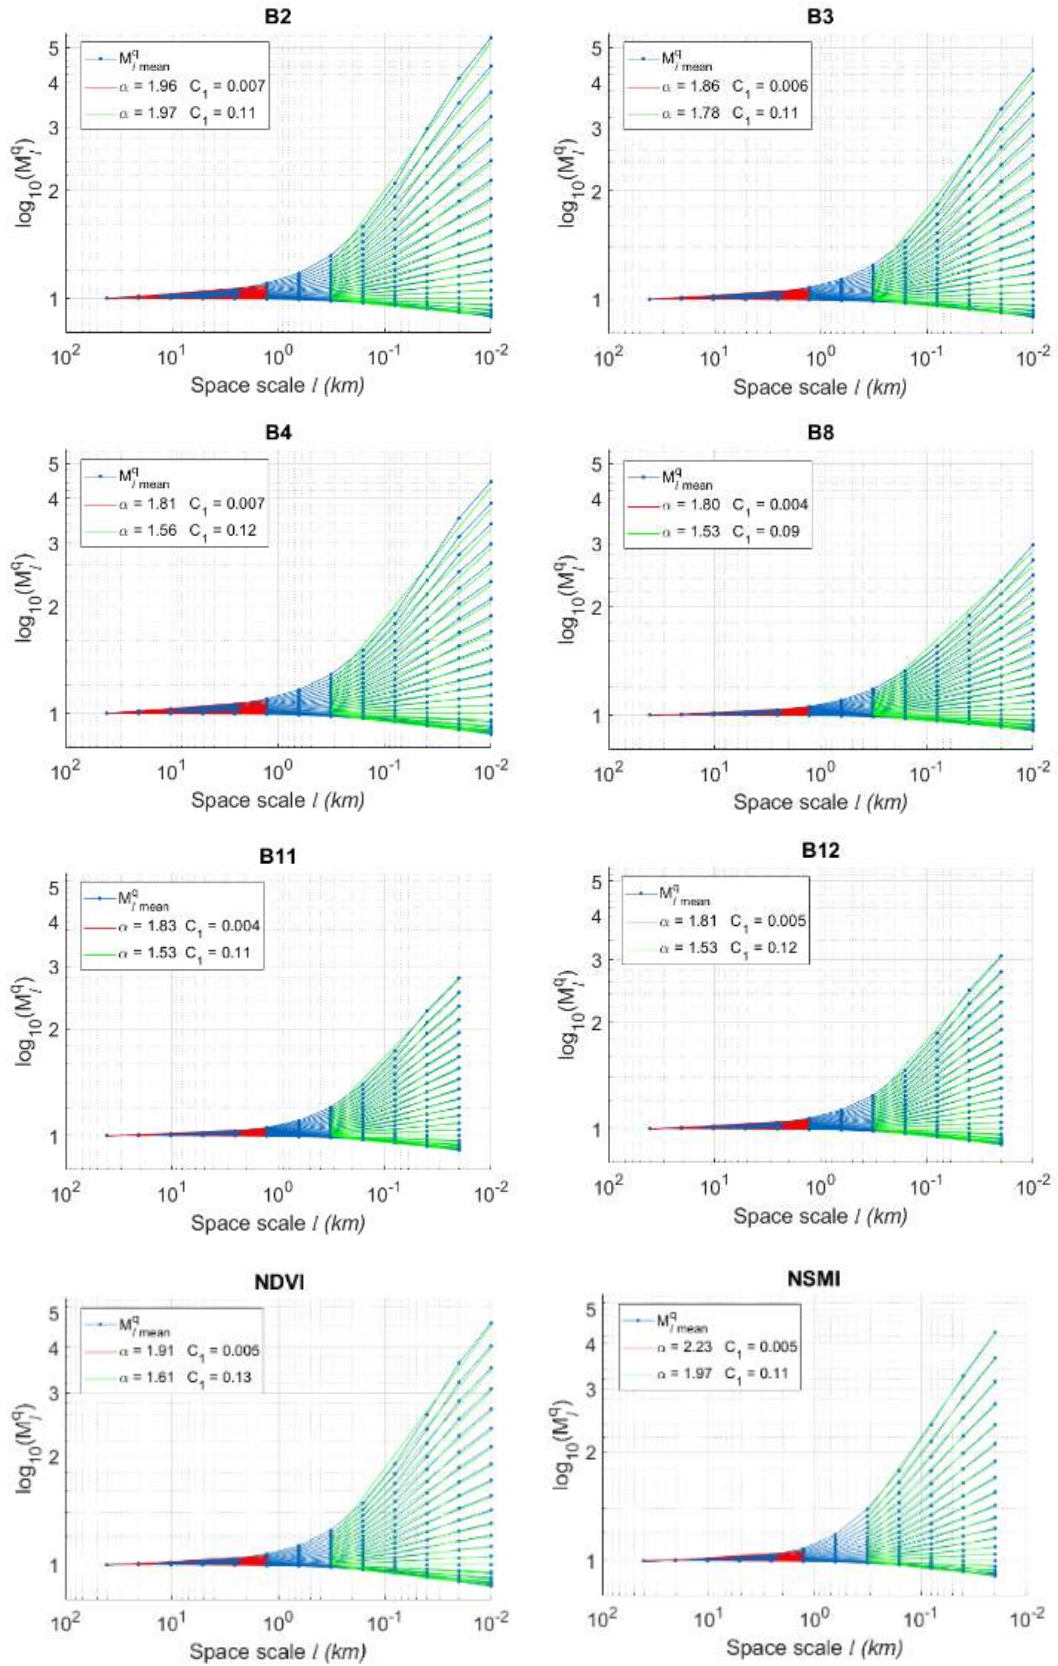


Figure 4.17 : Moments statistiques moyens estimés à partir des bandes et indices Sentinel-2, pour la période Janvier-Décembre 2016. Les droites en rouge et vert correspondent aux régressions linéaires réalisées respectivement sur les gammes  $I$  et  $II$ .

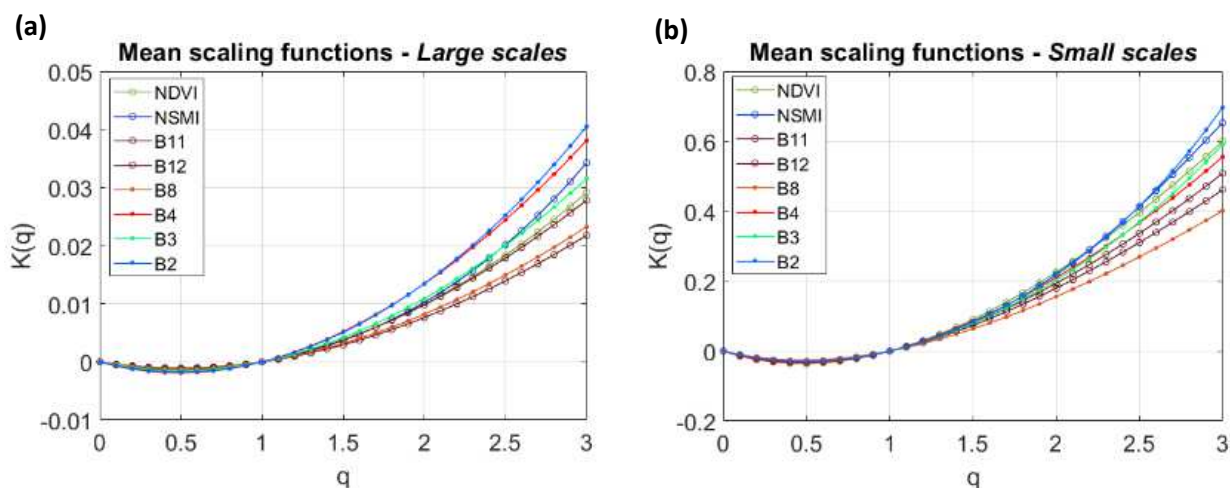


Figure 4.18 : Fonctions d'échelle estimées à partir des moments statistiques moyens de la figure 4.17, pour les gammes I (a) et II (b).

### 4.3.2 Dynamique temporelle des propriétés d'échelle

Afin de compléter l'étude, nous nous sommes également intéressés à l'évolution temporelle des propriétés d'échelle de nos produits S2. Ainsi, à partir des estimateurs statistiques obtenus pour chacune des dates de la période Janvier-Décembre 2016, j'ai pu estimer les paramètres multi-échelles journaliers, et ce pour les deux gammes d'échelles précédemment détectées. Notons que les paramètres multi-échelles journaliers sont estimés pour les *gammes I et II*, lesquelles ont été mises en évidence par l'analyse globale (estimateurs statistiques moyens). Ici la position de chacune de ces gammes n'est pas réestimée image par image de manière à pouvoir comparer la loi d'échelle de chaque produit sur des gammes strictement identiques et ainsi mettre en évidence certains comportements saisonniers. Nous verrons en section 4.4.2.4 que ces comportements temporels sont justement liés à l'évolution des gammes d'échelles au cours de la période d'étude.

#### 4.3.2.1 Cycle saisonnier *fine échelle* des réflectances de surfaces

La figure 4.19 représente les séries temporelles du paramètre spectral  $\beta$  pour les six bandes et les deux régimes d'échelles (les indices seront présentés plus loin). **Nous constatons que la pente spectrale semble présenter un cycle saisonnier sur la gamme *fine échelle* (gamme II) alors qu'aucun comportement particulier ne semble présent à *large échelle* (gamme I).** De plus, la dynamique des valeurs de  $\beta$  est plus élevée à *fine échelle* ( $0.8 < \beta < 2.4$ ) qu'à *large échelle* ( $0 < \beta < 0.9$ ).

Si l'on analyse plus en détail le cycle pour  $l < 400$  m, les bandes du visible (B2, B3, B4) révèlent une dynamique caractérisée par des valeurs minimales en février, août puis décembre ( $\beta \approx 1.5$ ) et des pics de valeurs vers mai-juin puis octobre ( $\beta \approx 1.9$ ). Pour les

bandes du moyen infrarouge (B11, B12), les maxima sont placés aux mêmes moments que pour les bandes du visible mais ils ne semblent pas présenter la même intensité : le pic observé en mai-juin est très marqué – avec des valeurs atteignant les 2.3 (flèche sur le graphe) – alors que celui d’octobre est plus faible (voire presque inexistant pour B11).

Dans le cas de la bande du proche infrarouge B8, nous observons à *fine échelle* un cycle qui semble inversé par rapport aux autres bandes, correspondant à des valeurs minimales pour les mois de mai-juin puis octobre. De plus, l’exposant spectral de B8 montre une dynamique bien plus marquée en deuxième moitié de période – valeurs de  $\beta$  chutant de 1.5 (juillet) à 0.9 (octobre, flèche sur le graphe) – qu’en première moitié de période ( $1.4 < \beta < 1.7$ ). Ainsi, pour le mois d’octobre, les images acquises dans le proche infrarouge semblent perdre en autocorrélation spatiale, se rapprochant du comportement spectral d’un bruit décorrélié ( $\beta < 1$ ).

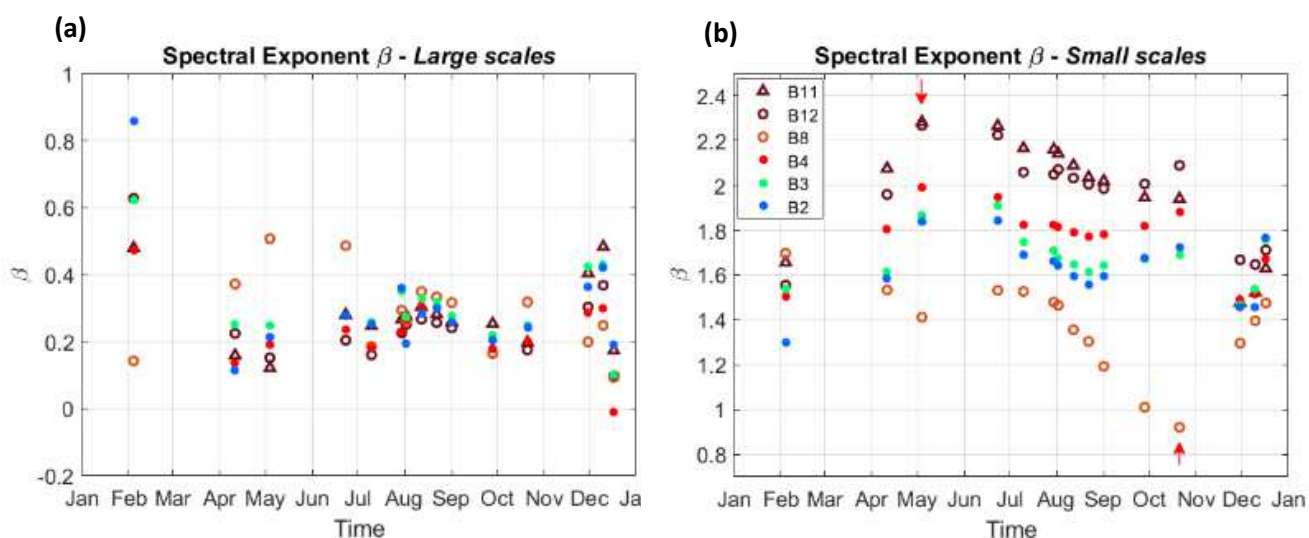
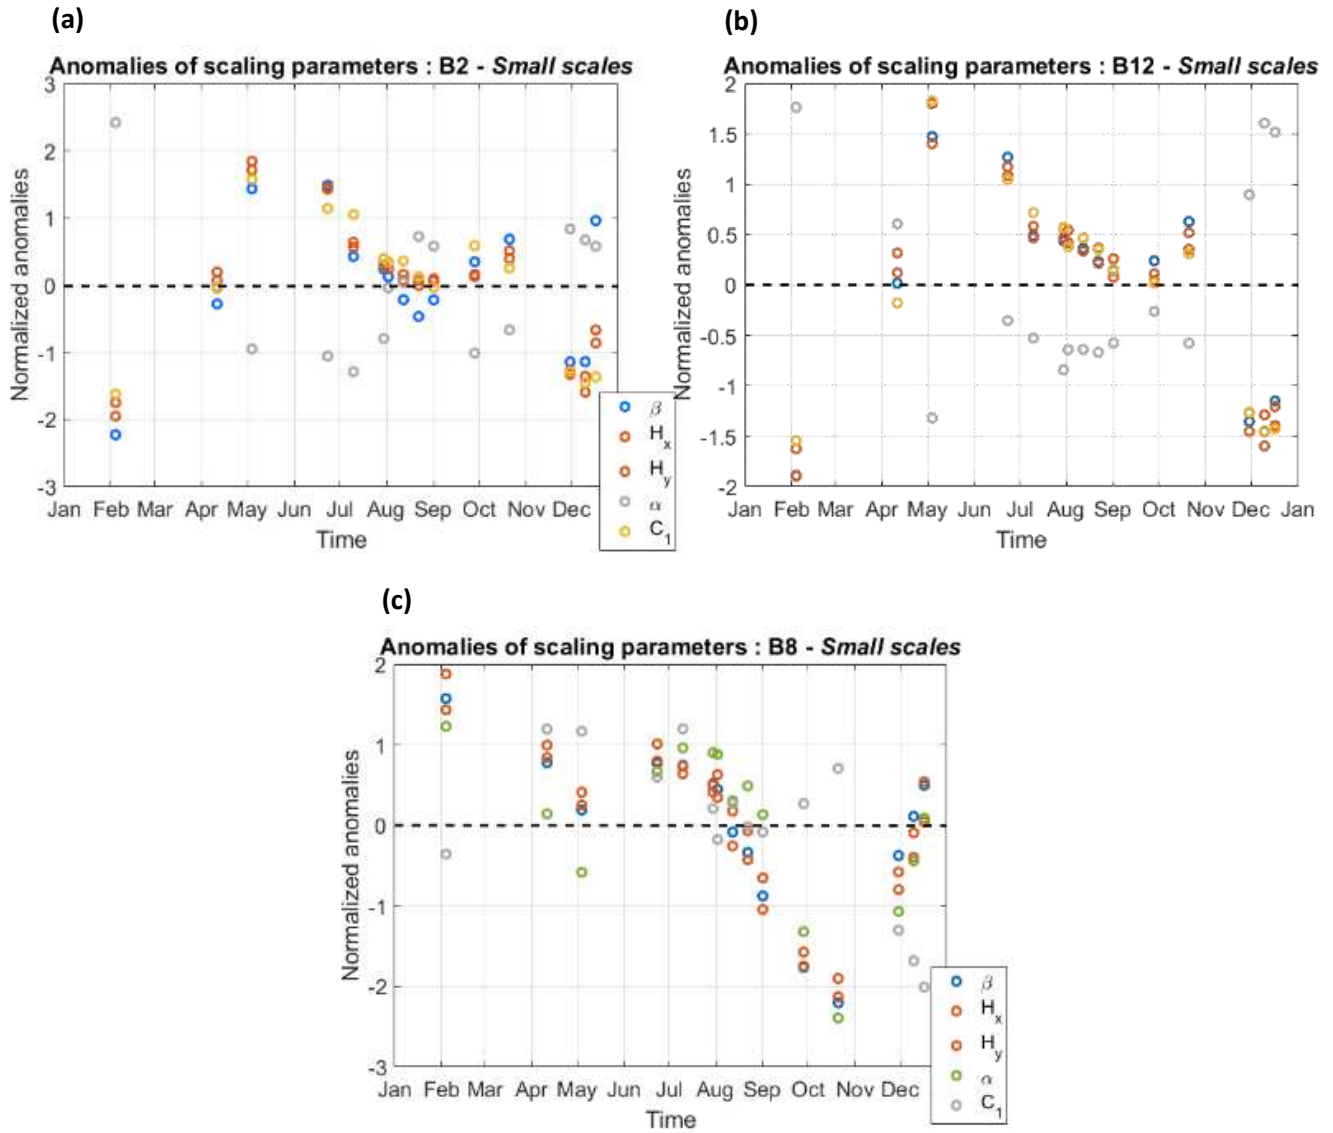


Figure 4.19 : Séries temporelles des exposants spectraux des bandes S2 sur la période Janvier-Décembre 2016, pour les gammes I (a) et II (b).

Ce cycle saisonnier *fine échelle* se retrouve aussi sur les autres paramètres multi-échelles  $H$ ,  $\alpha$  et  $C_1$ . Pour illustrer cela, nous avons tracé les anomalies normalisées des différents paramètres obtenus à partir des trois bandes B2, B8 et B12 (fig.4.20), représentant respectivement le comportement des réflectances acquises dans le visible, proche et moyen infrarouge (le détail des séries temporelles correspondants à l’ensemble des bandes étudiées se trouve en Annexe I). Dans le cas des bandes B2 et B12, nous constatons que les différents paramètres d’échelle présentent la même dynamique temporelle, excepté pour l’indice de multifractalité  $\alpha$  (fig.4.20.a-b). Ainsi, durant le mois de mai, les valeurs maximales de  $H$  et de  $C_1$  traduiraient respectivement un lissage plus important (intégration fractionnaire plus élevée) et une dispersion plus grande du signal que durant les autres mois de l’année. Pour ce qui est de la bande B8, le cycle du paramètre  $\beta$  est également retrouvé sur  $H$  et  $\alpha$  (fig.4.20.c).



Dans ce cas, le signal présent dans les images acquises en octobre et dans le proche infrarouge semblerait caractérisé par un lissage minimal voire nul (valeurs de  $H$  tendant vers 0, cf. Annexe I) et une multifractalité plus faible ( $\alpha \approx 1.4$ ). Le paramètre  $C_1$  quant à lui ne semble pas suivre de cycle particulier pour cette bande.



**Figure 4.20 : Anomalies normalisées obtenues à partir des séries temporelles des paramètres multi-échelles pour les bandes B2 (a), B12 (b) et B8 (c), sur la période Janvier-Décembre 2016 et pour la gamme II seulement.**

Nous observons également un cycle saisonnier *fine échelle* à travers la dynamique temporelle de la qualité de la loi d'échelle. La figure 4.21 représente l'évolution des coefficients de détermination  $R^2$  estimés après régression linéaire de chaque spectre obtenu durant la période, et ce pour les différentes bandes étudiées. Tout d'abord, une remarque générale peut être faite sur la bonne qualité de la loi d'échelle tout au long de l'année :  $R^2 > 0.95$  pour chaque bande, ce qui montre donc la présence de propriétés fractales sur chacune des dates prises séparément et complète donc les résultats observés à partir du comportement moyen de la section 4.3.1. Ensuite, nous constatons que les bandes du moyen infrarouge (B11, B12) présentent un cycle comparable à celui de leurs paramètres  $\beta$ , avec un  $R^2$  maximal en avril-mai. De même, la bande du proche infrarouge (B8) semble également suivre le comportement de  $\beta$ , avec une chute importante du  $R^2$  en octobre. Par contre, les coefficients  $R^2$  des bandes du visible ne présentent pas d'allure particulière, pouvant être dû à la faible dynamique du  $R^2$  comparée à celle des autres bandes. On peut remarquer tout de même un maximum de  $R^2$  en avril, comparable à celui de leurs paramètres  $\beta$  ayant lieu en mai.


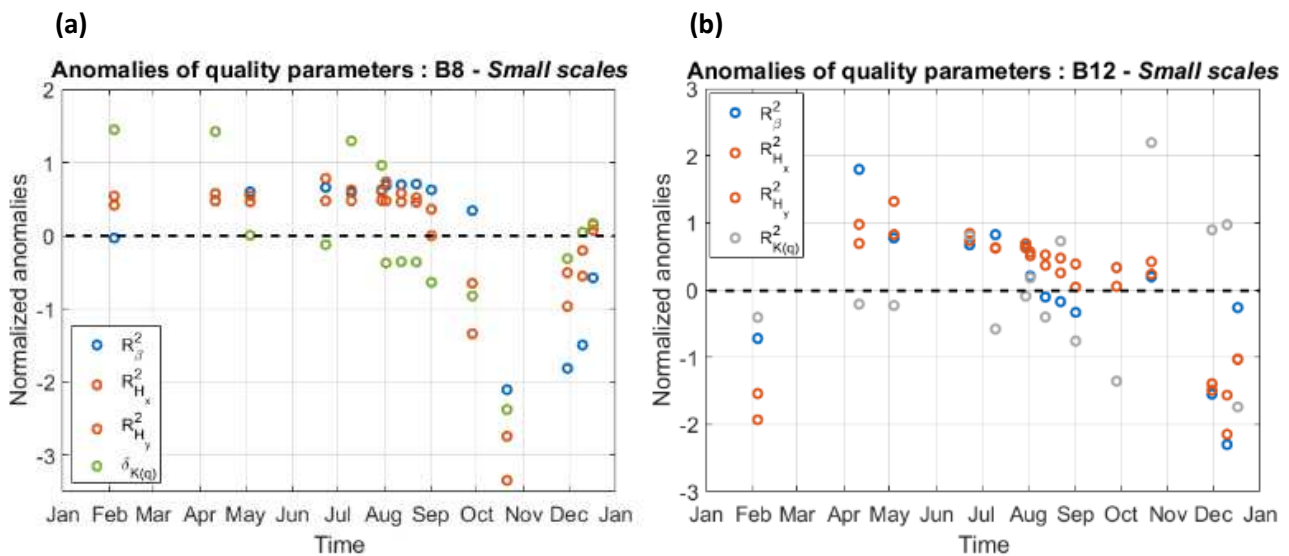


Figure 4.21 : Séries temporelles des coefficients de détermination issus des régressions linéaires réalisées sur les spectres des bandes S2, sur la période Janvier-Décembre 2016, pour la gamme II.



Si l'on considère les autres estimateurs statistiques, un comportement similaire de la qualité de la loi d'échelle peut s'observer. En effet, dans le cas de la bande du proche infrarouge (fig.4.22.a), nous pouvons noter la même chute en octobre pour les coefficients  $R^2$  des spectres et fonctions de structure, et pour l'intervalle de confiance ( $\delta$  à 95%) des moments (ce dernier correspondant à la moyenne des  $\delta$  obtenus après régression linéaire sur chaque courbe de moment). De la même manière, la bande du moyen infrarouge B12 semble aussi révéler une dynamique comparable pour  $R_{\beta}^2$ ,  $R_{Hx}^2$  et  $R_{Hy}^2$  (fig.4.22.b). En revanche, les moments ne semblent pas présenter la même évolution vis-à-vis de leur coefficient  $R_{K(q)}^2$ . La bande du visible B2 a été ajoutée en Annexe J, ne révélant pas de cycle ou de comportement particulier quant à la qualité de sa loi d'échelle.



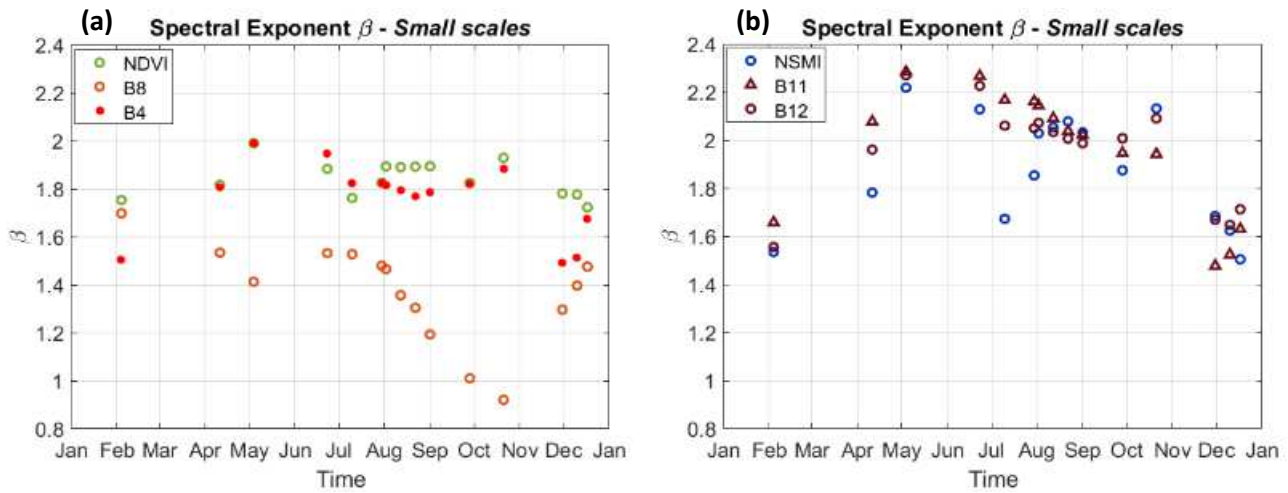
**Figure 4.22 : Anomalies normalisées obtenues à partir des séries temporelles des paramètres de qualité multi-échelle ( $R^2$  et  $\delta$ ) pour les bandes B8 (a) et B12 (b), sur la période Janvier-Décembre 2016, pour la gamme II.**

#### 4.3.2.2 Dynamique temporelle *fine échelle* des indices optiques

Ici, nous allons nous intéresser à l'évolution des paramètres d'échelles des indices de végétation et d'humidité du sol au cours du temps. Plus particulièrement, nous allons voir si la dynamique observée à *fine échelle* (*gamme II*) sur les réflectances de surface se retrouve au niveau de ces indices.

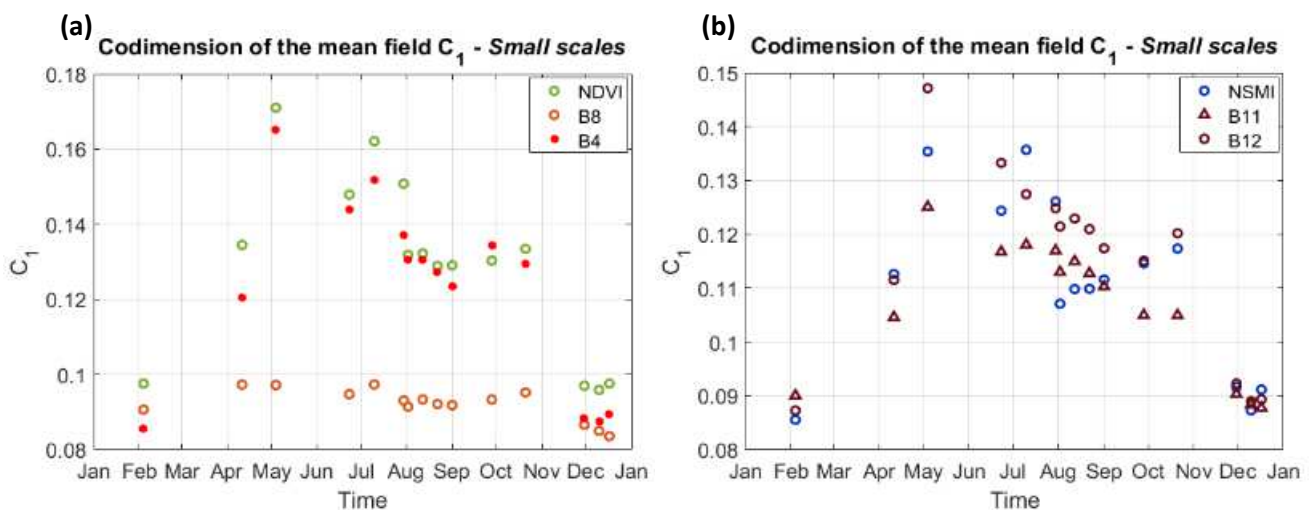
La figure 4.23 compare les séries temporelles des paramètres spectraux  $\beta$  de chaque indice avec leurs bandes respectives les ayant générés. Pour l'indice de végétation NDVI, la pente spectrale révèle une dynamique proche de celle du paramètre  $\beta$  de la bande B4, mais un comportement totalement différent de la bande B8. Le lien indice/bandes est en accord avec ce que nous avons observé vis-à-vis du comportement moyen des spectres – pentes

similaires entre les spectres moyens du NDVI et de la bande B4 (section 4.3.1.2). Dans le cas de l'indice d'humidité NSMI, son paramètre  $\beta$  et celui des bandes B11 et B12 suivent une dynamique comparable – mis à part pour quelques dates comme celles du mois de juillet où le NSMI présente un  $\beta$  plus faible que celui des bandes. Comme pour le NDVI, ces résultats sont en accord ceux présentés par les spectres moyens.



**Figure 4.23 : Séries temporelles des exposants spectraux obtenus pour le NDVI et les bandes B8/B4 (a), et pour le NSMI et les bandes B11/B12 (b). Ces résultats correspondent à la période Janvier-Décembre 2016, pour la gamme II.**

Pour ce qui est du paramètre  $H$ , des résultats équivalents à ceux du paramètre  $\beta$  sont présentés en Annexe K. Dans le cas de  $C_1$  (fig. 4.24), nous remarquons les mêmes comportements temporels pour le NDVI et la bande B4. D'autre part, le NSMI et les deux bandes B11 et B12 présentent également la même dynamique de leur paramètre  $C_1$ . Ainsi, le même lien indice/bandes est donc observé qu'avec les pentes spectrales ou le paramètre  $H$  (dans le cas de  $\alpha$  aucun lien particulier n'a été détecté).



**Figure 4.24 : Séries temporelles des paramètres  $C_1$  pour le NDVI et les bandes B8/B4 (a), et pour le NSMI et les bandes B11/B12 (b). Ces résultats correspondent à la période Janvier-Décembre 2016, pour la gamme II.**

**D'après l'évolution temporelle des paramètres multi-échelles présentés ci-dessus, le comportement du NDVI semble suivre celui de la bande B4 et non de B8, alors que le comportement du NSMI paraît suivre celui des deux bandes B11 et B12.** Ainsi, bien que la bande B8 soit très sensible à la végétation (réfléchissant bien plus dans le proche infrarouge que dans le rouge), cette bande impacterait peu voire pas du tout le comportement multifractal de l'indice de végétation. Cela semble surprenant d'autant plus que, par comparaison, l'indice d'humidité du sol semble en lien avec les propriétés multifractales des réflectances du moyen infrarouge (du moins pour trois paramètres multi-échelles sur quatre).

Une explication à ce comportement inattendu du NDVI pourrait être en lien avec les résultats trouvés par [Lovejoy et al. \(2008b\)](#). En effet, ces derniers ont montré que les lois d'échelle d'indices optiques tels que le NDVI étaient altérées par rapport aux lois des bandes spectrales les ayant estimés. Cette altération serait liée au fait que la combinaison des bandes ne soit effectuée qu'à une échelle précise (la résolution du capteur), fournissant ainsi des indices dont les statistiques ne sont correctes qu'à cette échelle spatiale et se dégradent pour les échelles supérieures. Selon cette hypothèse, on pourrait donc s'attendre à ce que la combinaison des bandes B4 et B8 altère les propriétés fractales initialement présentes dans les réflectances de surface. En revanche, cela n'expliquerait pas pourquoi ce même phénomène ne se reproduit pas sur le NSMI. Néanmoins, un autre élément observable sur nos résultats pourrait aider à interpréter cette différence. D'après les figures 4.23.a-24.a, nous remarquons que pour la majorité des dates étudiées les paramètres  $\beta$  et  $C_1$  de la bande B4 présentent des valeurs différentes et supérieures à celles de la bande B8 (ce qui se constate également d'après les paramètres issus de l'analyse globale). Or, les valeurs de ces mêmes paramètres obtenues pour les bandes B11 et B12 sont en revanche très comparables d'une bande à l'autre, et ce tout au long de la période (fig.4.23.b-24.b). Il semble que la combinaison de bandes dont les propriétés multi-échelles sont relativement différentes génèrerait un produit qui hériterait des propriétés multi-échelles de la bande ayant le signal le plus autocorrélé (forte pente spectrale) et le plus dispersé. Dans le cas de bandes aux propriétés similaires, le produit obtenu semble hériter des propriétés d'échelle des deux bandes originales. Ainsi, bien que les méthodes de calcul d'indices optiques permettent de mettre en évidence certaines variables de la surface comme la végétation dans le cas du NDVI, ces méthodes ne retranscrivent pas toujours l'information multi-échelle attendue comme celle caractérisant les réflectances du proche infrarouge fortement liées à la végétation.

Pour conclure sur cette partie résultat, l'analyse multifractale des produits S2 a révélé la présence de deux régimes d'échelles, présentant des propriétés fractales et multifractales distinctes, et séparés par une échelle de transition située autour des 450 m. Nous avons observé que la longueur d'onde d'acquisition pouvait influencer la valeur de certains paramètres d'échelle. En particulier, les réflectances acquises dans le proche infrarouge montrent un comportement multifractal qui paraît se détacher de celui des autres produits étudiés. Pour la gamme *fine échelle*, un cycle saisonnier a été observé, notamment pour cette bande du proche infrarouge qui présente une dynamique prononcée, avec une modification importante de ses paramètres d'échelle en octobre, mais aussi de la qualité de la loi d'échelle. **Cela met en évidence le fait que la structure spatiale de la zone étudiée varie au cours de l'année, et impacterait donc les propriétés fractales des réflectances de surface. De plus, cet effet semble différent selon la bande d'acquisition, avec un cycle inversé entre les bandes du proche infrarouge et celles du visible/moyen infrarouge. Cette évolution constatée et tous les résultats ici mentionnés seront discutés dans la section suivante.**

## 4.4 Discussion

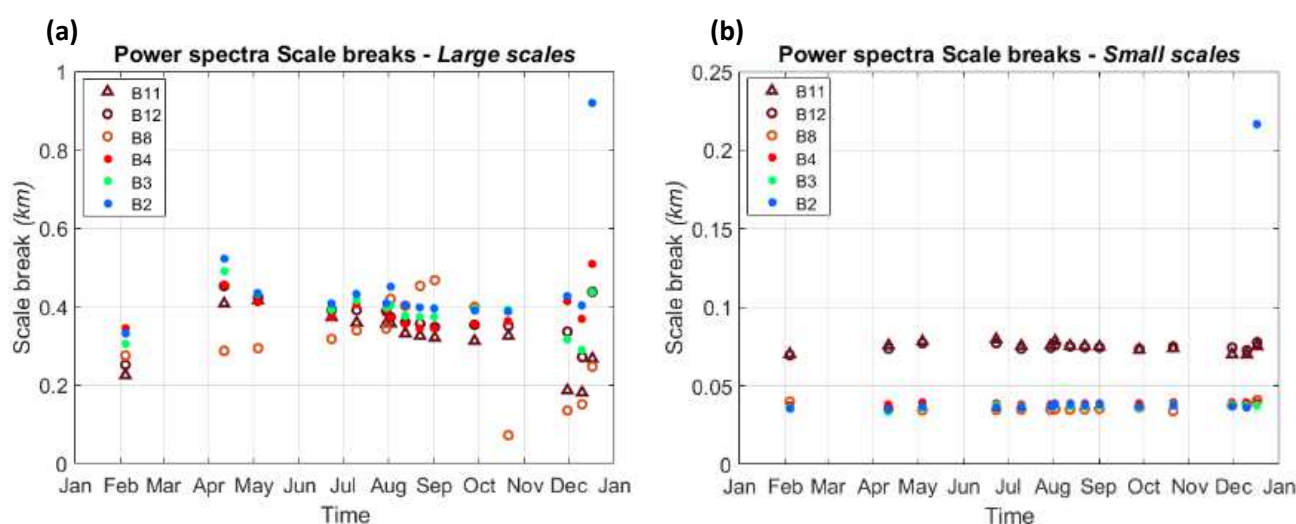
Dans cette partie, nous allons tout d'abord revenir sur la rupture *fine échelle* observée sur les spectres de puissance, afin de déterminer la raison possible à ce phénomène systématique, présent sur chacune des bandes étudiées. Puis, dans un deuxième temps nous allons proposer des explications à la présence des deux régimes d'échelle ainsi qu'au cycle saisonnier détectés sur la gamme *fine échelle*.

### 4.4.1 Mise en évidence des possibles limites de performance de capteurs optiques

#### 4.4.1.1 Une rupture *fine échelle* indépendante du temps et de la surface observée

En section 4.3.1.1, nous avons vu que la rupture *fine échelle* *R2*, séparant les gammes *II* et *III* précédemment identifiées à partir des spectres moyens, se situait le plus souvent vers 40 m pour les bandes dont la résolution étaient de 10 m, et à 75 m pour les bandes définies à 20 m. Ainsi, il semblerait qu'il y ait un lien entre la position de cette rupture et la résolution des bandes S2. Ci-après, pour chaque spectre obtenu durant la période d'étude et pour chaque bande, sont tracés d'une part l'évolution temporelle des ruptures *large échelle* *R1* détectées par segmentation (séparant les gammes *I* et *II*) (fig.4.25.a), puis l'évolution des ruptures *R2* d'autre part (fig.4.25.b). Nous voyons clairement que toutes les bandes présentent une rupture *R2* dont la position est constante au cours de la période d'étude (sauf

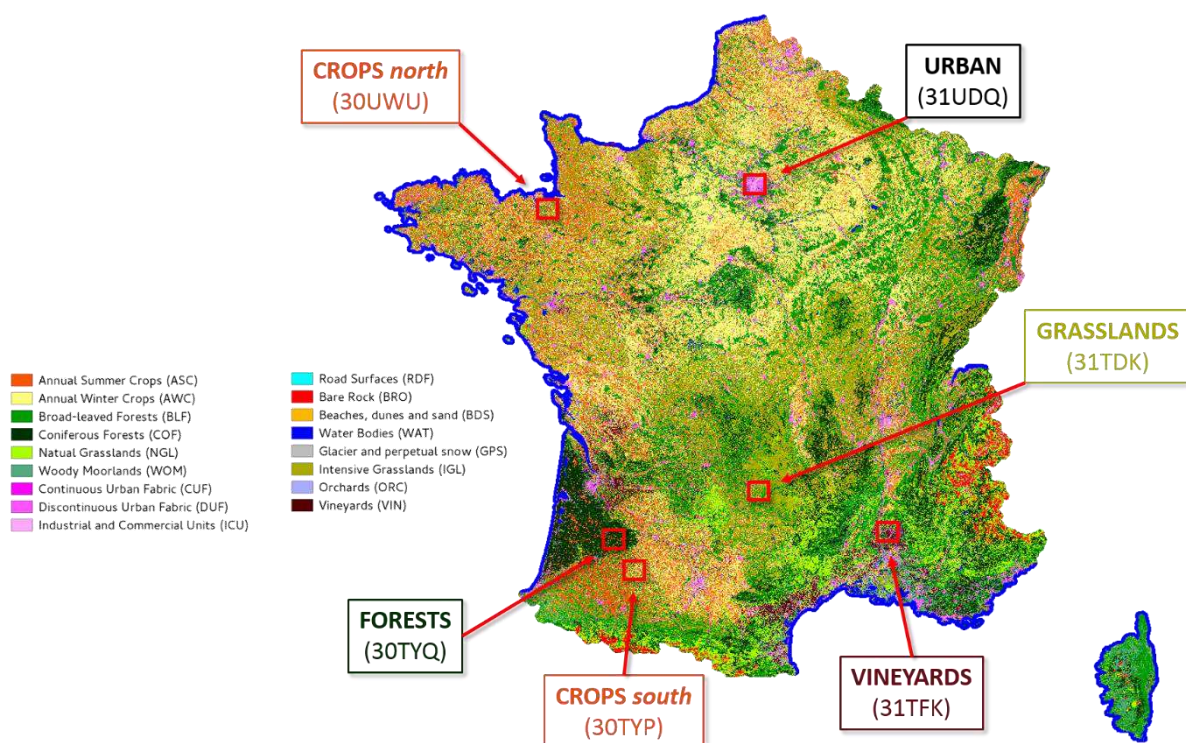
à la dernière date pour la bande B2). En revanche, à *large échelle*, la rupture  $R1$  varie au cours du temps, révélant un cycle saisonnier comparable à celui observé en section 4.3.2 pour les paramètres multi-échelles. Ces résultats montrent que les deux ruptures détectées sur les spectres sont de natures différentes : la rupture *large échelle*  $R1$  semble directement liée au signal physique mesuré, variant au cours des saisons, alors que la rupture *fine échelle*  $R2$  paraît indépendante du signal acquis durant la période d'étude. **Ainsi, une hypothèse serait que cette rupture *fine échelle*, présente de nature systématique, soit liée aux conditions d'acquisition et de traitement du signal qui modifieraient les propriétés statistiques des réflectances de surface lorsque l'on se rapproche de la résolution du capteur.** Le phénomène observé ici semble comparable à celui que nous avons pu voir sur les spectres des données MODIS (et DisPATCh) dans le chapitre précédent (section 3.3.1).



**Figure 4.25 : Séries temporelles de la position des ruptures large échelle  $R1$  (a) et fine échelle  $R2$  (b) estimées à partir des spectres de puissance des bandes S2, pour la période Janvier-Décembre 2016.**

Pour appuyer cette hypothèse nous avons effectué des analyses supplémentaires. Nous avons vérifié que cette rupture n'était pas liée à la zone d'étude, dont la structure spatiale serait éventuellement définie par une échelle caractéristique située à la dizaine de mètres et marquant la transition entre deux régimes d'échelle. **Pour cela, nous avons sélectionné plusieurs régions de France ayant une occupation du sol différente.** Ces régions ont pu être identifiées grâce aux produits d'occupation des sols fournis par le CES OSO (Centre d'Expertise Scientifique Occupation des Sols; <http://osr-cesbio.ups-tlse.fr/~oso>). Plus particulièrement, nous avons utilisé la carte d'occupation des sols de l'année 2016, obtenue à partir de produits S2, et présentée en figure 4.26. En plus de la tuile habituelle (30TYP), cinq nouvelles tuiles S2 ont été ajoutées à notre étude, correspondant à cinq types de surface ou classes : *cultures (crops)*, *forêt (forest)*, *urbain (urban)*, *vignes (vineyards)* et *prairies*

(grasslands). Les zones ont été choisies de manière que les images S2 extraites contiennent pour chaque classe une majorité de pixels appartenant à la classe en question. Nous pouvons noter que deux zones sont identifiées dans la classe *cultures* : *crops south* correspondant à la zone étudiée dans la section précédente (tuile 30TYP), et *crops north* qui est une autre zone essentiellement composée de parcelles agricoles mais située dans le Nord-Ouest de la France (tuile 30UWU). Ainsi, pour les six zones, nous avons extrait les réflectances de surface acquises dans deux bandes spectrales définies à 10 m (B2, B8) et à deux dates de l'année 2016 (été, automne). Le tableau 4.4 précise la position des ruptures *R1* et *R2* détectées dans les spectres de puissance. De manière générale, en considérant l'ensemble des zones, bandes et dates fournies, ces résultats montrent une rupture *R2* qui varie entre 32 m et 42 m, et une rupture *R1* qui se situe entre 72 m et 1 km. **La position de la rupture *fine échelle* *R2* semble donc peu impactée par le type de surface, la date d'acquisition et la bande spectrale (quand elle est définie selon une même résolution), par comparaison à la rupture *large échelle* *R1* qui varie bien plus d'un cas à l'autre.**



**Figure 4.26 : Six zones d'étude correspondant aux cinq types de surface (cultures, forêt, urbain, vignes, prairies) identifiés à partir de la carte de France d'occupation des sols 2016 du CES OSO.**



	Summer				Autumn			
	B2		B8		B2		B8	
	R1	R2	R1	R2	R1	R2	R1	R2
<i>crops<sub>south</sub></i>	440	36	340	35	390	37	72	34
<i>forests</i>	860	32	1000	39	910	34	210	38
<i>crops<sub>north</sub></i>	310	36	380	34	380	33	460	41
<i>urban</i>	-	40	-	42	-	39	-	40
<i>vineyards</i>	150	34	180	35	150	34	130	35
<i>grasslands</i>	280	37	350	34	140	37	250	37

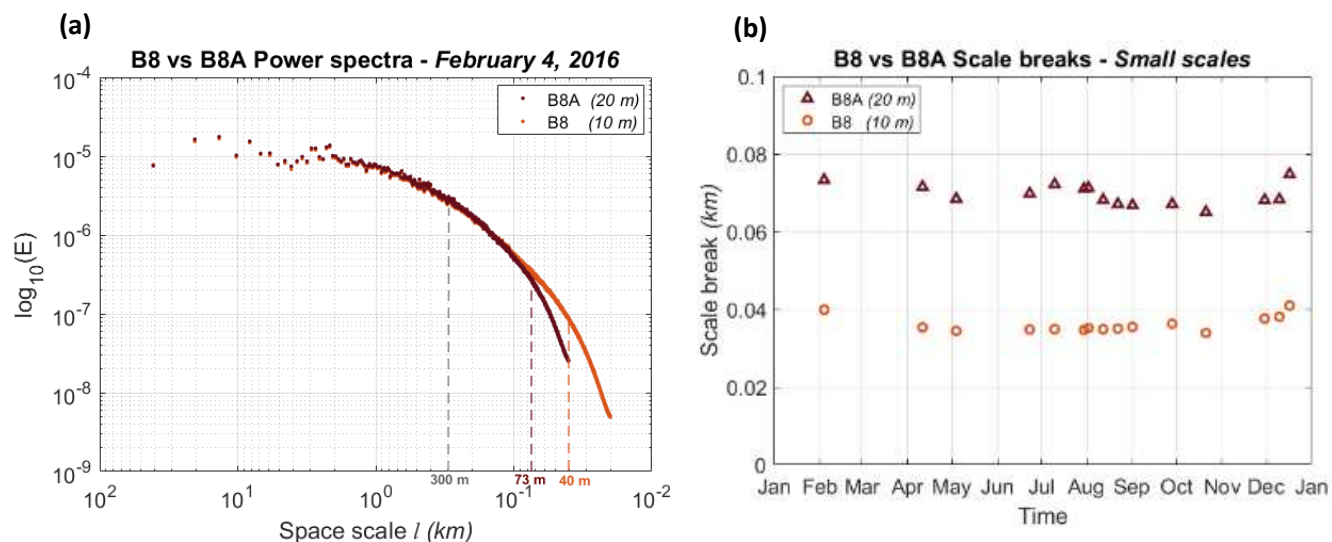
**Tableau 4.4 : Positions (en mètres) des ruptures R1 et R2 estimées à partir des spectres de puissance correspondant à six types de surface, observées dans les bandes B2 et B8, en été et en automne 2016.**

#### 4.4.1.2 Impact de la Fonction de Transfert de Modulation sur les propriétés statistiques *fine échelle* des réflectances de surface

Ainsi, bien que la surface des zones analysées ci-dessus présente une structure spatiale distincte liée au changement d'occupation des sols, la même rupture est détectée près de la résolution du capteur. Cette rupture ne semble donc pas correspondre à une échelle de transition entre deux régimes caractéristiques de la surface. **En revanche, elle pourrait être une conséquence du système d'acquisition qui affecte les hautes fréquences spatiales des images.** Dans tout système optique, ce phénomène est modélisé par une fonction appelée FTM (Fonction de Transfert de Modulation; [Norton et al., 1977](#)). Celle-ci définit la capacité du système à transmettre les fréquences spatiales de la scène observée. Elle est affectée par plusieurs composants du système tels que l'objectif (la lentille) et les détecteurs, mais aussi par des facteurs externes comme la température ou la diffusion atmosphérique. Bien que ces derniers facteurs puissent modifier la FTM après lancement du capteur dans l'espace, celle-ci varie très peu au cours du temps. De cette manière, elle pourrait donc être la raison à la rupture systématique que nous observons aux fréquences maximales acquises par le capteur S2.


De plus, afin de mettre en évidence l'effet de cette fonction de transfert instrumentale indépendamment du signal mesuré, nous avons comparé le comportement multi-échelle d'images acquises sur la même zone, pour les mêmes dates, mais pour des résolutions différentes. Pour cela, les spectres de la bande B8 ont été comparés à ceux de la bande B8A. Cette dernière bande est également située dans le proche infrarouge, mais est en revanche définie à une résolution de 20 m en raison de sa largeur qui est bien plus petite que celle de B8 (cf. section 4.2.2.2). Bien que ces deux bandes acquièrent un signal portant la même

signification physique, la position de la rupture *fine échelle* R2 est bien différente d'une bande à l'autre. Cela peut se voir nettement sur les spectres de la figure 4.27.a, révélant des comportements identiques pour les échelles inférieures à la centaine de mètres (ayant la même rupture *large échelle* R1 située vers les 300 m), mais présentant des différences croissantes aux échelles plus fines. Cela semble lié aux différentes ruptures *fine échelle* détectées entre les deux bandes : à 73 m pour B8A, à 40 m pour B8. De plus, nous remarquons que le rapport entre l'échelle de rupture et l'échelle minimale (c'est-à-dire la résolution de la bande) est comparable pour chacune des bandes :  $l_{rupture} \approx 4 \times l_{min}$ . Cette relation paraît présente de manière constante tout au long de la période (fig.4.27.b).



**Figure 4.27 : Spectres de puissance à la date du 4 février 2016 (a) et séries temporelles de la position des ruptures fine échelle R2 sur la période Janvier-Décembre 2016 (b), pour les bandes du proche infrarouge B8 et B8A.**

L'ensemble de ces résultats montrent que la rupture R2 systématiquement observée sur les spectres des produits S2 ne peut être causée que par le système d'acquisition des images optiques. Dans le cadre des procédures de validation et de calibration des produits S2, [Gascon et al. \(2017\)](#) ont déterminé la fonction de transfert de modulation de l'imageur MSI, après lancement du satellite S2-A. Celle-ci a été estimée en appliquant la méthode du "slanted-edge" ([Reichenbach et al., 1991](#)), qui a souvent été utilisée pour déterminer la FTM de capteurs spatiaux comme Landsat ([Carnahan and Zhou, 1986](#)) ou Ikonos ([Choi, 2002](#)). La figure 4.28 présente la FTM qu'ils ont obtenue pour la bande B2 (courbe en pointillés), à partir d'une image acquise en Arizona (Etats-Unis). Nous constatons effectivement que cette fonction décroît avec la fréquence spatiale, pour atteindre une valeur minimale d'environ 0.2 à la fréquence d'échantillonnage  $f_s$  (associée à la résolution du capteur, c'est-à-dire 10 m). A partir de l'évolution de cette courbe dans la gamme de fréquences comprises entre  $0.1 f_s$  et  $0.5 f_s$ , [Gascon et al. \(2017\)](#) ont également estimé une courbe "modèle" (courbe pleine en fig.4.28).



*Figure 4.28 : Fonction de Transfert de Modulation de la bande B2 estimée et modélisée à partir d'une image S2 acquise sur la ville de Maricopa (Arizona, Etat-Unis). D'après les résultats de [Gascon et al. \(2017\)](#), pour lesquels la FTM a été obtenue ici suivant la direction des lignes de l'image (Across Track), selon la méthode "slanted-edge" décrite dans [Viallefont-Robinet and Léger \(2010\)](#).*

#### 4.4.1.3 Modélisation de la rupture *fine échelle* à partir d'une simulation de champ multifractal

Afin de vérifier quel pourrait être l'impact de la fonction de transfert sur le spectre de puissance, j'ai généré une FTM selon le modèle de [Viallefont-Robinet and Léger \(2010\)](#). Ces derniers ont proposé un modèle paramétrique de FTM prenant en compte diverses caractéristiques du système telles que les effets de diffraction de la lentille et les effets d'échantillonnage du détecteur, ainsi que l'impact d'autres phénomènes comme le déplacement des charges électroniques ou la correction de la mise au point (focus) qui peut être réalisée après lancement du satellite. Ici, par soucis de simplicité et de rapidité, seuls les effets majeurs sur la FTM ont été pris en compte, soit la diffraction et l'échantillonnage. Ensuite, j'ai appliqué cette fonction sur un champ multifractal simulé (d'après la méthode en section 2.3.1) représentant le comportement multi-échelle du signal original non impacté par le système optique. L'opération a été réalisée dans le domaine de Fourier en appliquant la relation suivante :

$$I_{filtrée} = FTM \times I_{simu}$$


4.12

avec  $I_{filtrée}$  et  $I_{simu}$  les modules des transformées de Fourier des images correspondant respectivement au champ filtré par la FTM et au champ original simulé. Pour le calcul et la génération de la FTM, le détail des équations utilisées est donné en Annexe L. Deux paramètres sont à définir dans le modèle : (1) la fréquence d'échantillonnage du détecteur  $f_s$ ,

que nous avons fixée ici à la résolution du champ multifractal simulé, c'est-à-dire à  $1 \text{ pixel}^{-1}$  (notons que nous considérons ici une échelle exprimée en pixels, soit une fréquence en " $\text{pixel}^{-1}$ "), (2) la fréquence de coupure de la lentille  $f_c$  qui est responsable des effets de diffraction, que nous avons également définie à  $1 \text{ pixel}^{-1}$  par souci de simplicité. En réalité la valeur de  $f_c$  dépend des caractéristiques de la lentille (diamètre, distance focale) et de la longueur d'onde du rayonnement incident. Or, n'ayant pas accès à la valeur de la distance focale du capteur MSI, nous n'avons pas pu déterminer la fréquence de coupure réelle. Cependant, d'après les résultats de [Gascon et al. \(2017\)](#) (fig.4.28), la FTM qu'ils ont mesurée pour la bande B2 présente une valeur proche de 0 à la fréquence d'échantillonnage. Cela montre que, pour cette bande,  $f_c$  devrait donc se situer dans le voisinage de  $f_s$ , à des fréquences légèrement supérieures. Selon cette hypothèse, nous allons supposer par la suite que  $f_c \approx f_s = 1 \text{ pixel}^{-1}$ .

La figure 4.29 présente les spectres de puissance du champ original (courbe bleue), du champ affecté de la FTM en considérant seulement l'effet d'échantillonnage du détecteur (courbe marron foncé), puis uniquement l'effet de diffraction de la lentille (courbe marron clair), et enfin en considérant à la fois les effets d'échantillonnage et de diffraction (courbe rouge). **En observant ces spectres, nous constatons que les *fin*es échelles sont impactées par la FTM : l'énergie du signal semble atténuée pour les hautes fréquences, se traduisant par une augmentation de la pente spectrale pour des échelles inférieures à  $10 l_s$  (avec  $l_s = 1/f_s = 1 \text{ pixel}$ ).** Ce phénomène est plus prononcé lorsque les deux effets du système (diffraction et échantillonnage) sont pris en compte simultanément dans la fonction de transfert (spectre en rouge). Pour ce spectre, j'ai appliqué l'algorithme de segmentation qui a détecté une rupture d'échelle située à  $4.8 l_s$ . La relation trouvée ici entre la position de la rupture et la résolution de l'image est comparable à celle déduite de nos produits S2, pour lesquels le coefficient liant les deux échelles était proche de 4.

Le modèle de FTM que nous avons utilisé ici semble donc bien reproduire l'effet du système d'acquisition sur les hautes fréquences de l'image. Bien que la valeur de la fréquence de coupure ait été choisie de manière plus ou moins arbitraire, la rupture d'échelle que nous avons générée sur le spectre d'origine se trouve à une position similaire à celle de la rupture  $R2$  observée sur les spectres de nos bandes S2. **Ainsi, ces résultats apportent un argument théorique de validation quant à l'origine cette rupture *fine* échelle, qui est effectivement engendrée par le système d'acquisition.** De plus, la forte similarité des courbes rouge et marron clair de la figure 4.29 laisse supposer que la rupture soit principalement liée à l'effet de diffraction de la lentille.



**Figure 4.29 :** *Impact de la Fonction de Transfert de Modulation sur les spectres de puissance de champs multifractals simulés. La FTM a été générée à partir du modèle analytique décrit dans [Viallefont-Robinet and Léger \(2010\)](#).*

Le même travail a été réalisé en agrégeant le champ multifractal simulé d'un facteur 2, et en modélisant une FTM avec une fréquence d'échantillonnage deux fois plus petite (soit  $f_s = 0.5 \text{ pixel}^{-1}$  et  $l_s = 2 \text{ pixels}$ ). Ceci a été fait dans le but de simuler l'acquisition d'une image par une bande S2 à 20 m. Un comportement comparable à celui de la première simulation a été observé sur les spectres, avec une rupture d'échelle détectée à  $3.9 l_s$  (Annexe M). La même relation semblerait donc s'observer pour une fréquence d'échantillonnage divisée par deux, confirmant l'impact similaire de la FTM sur les images acquises à partir des bandes S2, qu'elles soient définies à 10 m ou 20 m.

Grâce au comportement spectral des produits S2 obtenus pour différentes dates, différentes localisations et plusieurs bandes d'acquisition, nous avons établi la présence d'une rupture d'échelle systématique située près de la résolution du capteur. Nous en avons ensuite proposé une explication et en avons démontré la consistance. En effet, nous avons pu montrer que cette rupture *fine échelle* serait en fait générée par le système optique faisant l'acquisition des images, plus particulièrement via sa Fonction de Transfert de Modulation, qui modifierait les propriétés statistiques des réflectances de surface pour les hautes fréquences spatiales.

#### 4.4.2 Des régimes d'échelles en lien avec l'hétérogénéité spatiale des surfaces agricoles

Nous allons maintenant nous intéresser à la rupture *grande échelle*  $R1$  observée sur les estimateurs statistiques. Plus particulièrement, nous allons proposer des raisons possibles à la présence des deux régimes d'échelle (*gamme I et II*), ainsi qu'au cycle saisonnier détecté sur la gamme *fine échelle* (*II*) qui semble particulièrement prononcé pour les réflectances du proche infrarouge.

##### 4.4.2.1 Des régimes aux propriétés multi-échelles distinctes

La rupture  $R1$  détectée à environ 450 m sur les bandes et indices S2 met en évidence deux régimes aux propriétés statistiques multi-échelles distinctes. Pour les échelles situées au-delà de cette échelle de transition (gamme I), l'analyse fractale a montré la nature peu corrélée et peu complexe des signaux étudiés à travers l'obtention de spectres plats (pente proche de 0) et de fonctions de structure à pente négative. De plus, les valeurs du paramètre  $C_1$  estimées sur cette gamme *large échelle* sont très faibles comparées à celles obtenues dans la littérature pour des processus multifractals comme la topographie, la pluie ou les nuages. **Ainsi, d'après le comportement moyen à large échelle (gamme I), la présence de propriétés multifractales dans nos produits semble peu voire pas du tout détectée, ce qui laisse penser qu'un modèle multi-échelle comme celui des Multifractales Universelles serait trop complexe et inadapté à ces échelles.** En effet, par comparaison à la gamme *fine échelle* (*II*), les fonctions d'échelle  $K(q)$  estimées à *large échelle* (*I*) ont une évolution presque linéaire, se rapprochant davantage d'un comportement monofractal. Des modèles plus simples que le modèle MU pourraient éventuellement suffire à caractériser les propriétés multi-échelles des bandes et indices S2 pour des échelles comprises entre le kilomètre et la dizaine de kilomètres. Une possibilité serait d'utiliser des modèles construits à partir de transformations ou filtrages appliqués à un modèle monofractal tel que le mouvement Brownien fractionnaire (Mandelbrot, 1975).

En revanche, le comportement multi-échelle moyen observé sur la gamme fine échelle (gamme II) révèle des propriétés fractales et multifractales plus complexes. Les processus analysés présentent des spectres et fonctions de structure aux pentes positives, reflétant une **variabilité spatiale complexe et de nature non-conservative qui semble comparable à la dynamique de processus atmosphériques par exemple.** De même, les paramètres universels estimés révèlent des valeurs similaires à celles obtenues dans la littérature, avec notamment un paramètre  $C_1$  bien plus élevé que sur les *larges échelles*. De plus, les fonctions d'échelles  $K(q)$  présentent un comportement convexe caractéristique des processus multifractals. **Par conséquent, pour des échelles comprises entre la dizaine et la centaine de mètres, le**



**comportement multi-échelle des produits S2 tend à justifier l'intérêt d'appliquer un modèle multifractal comme celui des Multifractales Universelles.**

D'après nos résultats, il semble que la cascade multiplicative caractérisant les réflectances de surface ne soit présente que sur la gamme *fine échelle*. Ainsi, il se pourrait que la rupture observée vers 450 m corresponde à l'échelle d'initialisation de la cascade, dite échelle "externe" ( $l_{ext}$ ). D'après [Lovejoy and Schertzer \(2006\)](#), cette échelle caractéristique peut se calculer à partir des moments empiriques, en prolongeant pour  $l > L$  les droites de régressions linéaires appliquées à chaque courbe  $\log(M_l^q)$  et sans contraindre le passage des droites par l'origine (pas de normalisation microcanonique, cf. section 2.3.2.3). La position de l'échelle externe est finalement estimée à partir de l'intersection des droites de régressions à l'échelle  $\log(l_{ext})$ . Cette échelle représente en quelques sortes l'échelle maximale pour laquelle la variabilité multifractale serait présente et observable dans le processus. [Lovejoy and Schertzer \(2006\)](#) ont par exemple estimé  $l_{ext}$  pour des champs de pluie ou de nuages acquis par satellite. Ils ont montré que, pour ces processus, cette échelle se situait non loin de l'échelle "planétaire", soit 20 000 km, correspondant à la plus grande distance "circulaire" observable de la surface terrestre. Ces résultats ont servi notamment à mettre en évidence la vaste étendue de la gamme d'échelles [1 - 5000] km pour laquelle les nuages présentaient des propriétés multifractales. Dans notre étude, le comportement multi-échelle observé sur les produits S2 laisserait supposer que la cascade sous-jacente est uniquement présente sur la gamme *fine échelle*, avec une éventuelle échelle externe située à la transition entre les deux régimes d'échelles ( $l_{ext} \approx 450$  m). Pour vérifier cela, nous avons appliqué la méthode de [Lovejoy and Schertzer \(2006\)](#) à l'ensemble des zones de 160 x 160 m<sup>2</sup> extraites dans la zone d'étude initiale (40 x 40 km<sup>2</sup>, tuile 30TYP), en fixant  $L = 160$  m et en cherchant  $l_{ext}$  vers des échelles supérieures à  $L$ . De manière plus détaillée, cela a consisté à suivre ces étapes :

1) *Calcul des moments empiriques de chaque sous-image sur la gamme [10 - 160] m.*

Ici, la normalisation microcanonique a été remplacée par une normalisation macrocanonique: les champs agrégés aux différentes échelles ont été normalisés par la moyenne de l'image entière (et non de la sous-image correspondante). Cela évite de contraindre les moments à 1 pour  $l = L$ , tout en normalisant (par soucis de réalisme physique) la cascade par rapport à une moyenne "globale" (macro) et non "locale" (micro).


2) *Estimation des moments moyens.*

Les moments calculés pour chaque sous-image ont été moyennés pour obtenir le comportement global de la cascade, représentatif de l'ensemble de la zone (grande image), mais toujours pour la gamme *fine échelle* [10 - 160] m.

3) *Détermination de l'échelle externe.*

Pour chaque courbe de moments moyens  $\log(M_l^q)$ , les droites de régressions estimées sur la gamme  $[10 - 160]$  m ont été prolongées sur  $l > L$ .  $l_{ext}$  a été déterminée à partir de l'intersection de ces droites.

La figure 4.30 présente les moments ainsi que la position de  $l_{ext}$  estimés selon cette méthode pour une image acquise dans la bande B8, le 21 octobre 2016. Les droites de régression s'interceptent vers une échelle située à  $l_{ext} \approx 430$  m, soit quasiment à la position de la rupture d'échelle  $R1$  estimée jusqu'à présent par segmentation ( $l_{seg}$ ). Ce même travail a été réalisé sur la bande B2, pour une image acquise à la même date (tableau 4.5) : nous avons également trouvé une échelle externe comparable à l'échelle de la rupture  $R1$ . **Cela confirme notre hypothèse sur l'origine de cette rupture d'échelle, qui correspondrait donc à l'échelle où se créerait la cascade *fine échelle*.** De plus, les paramètres  $\alpha$  et  $C_1$  estimés selon cette méthode (*macrocanonique*) présentent des valeurs fortement similaires à celles des paramètres obtenus jusqu'à présent (*microcanonique*). D'après le tableau 4.5, nous retrouvons pour B8 :  $\alpha_{macro} \approx \alpha_{micro} \approx 1.4$  et  $C_{1macro} \approx C_{1micro} \approx 0.10$ . Pour B2, nous obtenons :  $\alpha_{macro} \approx \alpha_{micro} \approx 1.8$  et  $C_{1macro} \approx C_{1micro} \approx 0.13$ . Ces résultats justifient l'intérêt d'appliquer cette méthode sur la gamme choisie (10 – 160 m), détectant le même comportement multifractal que pour la méthode *microcanonique*.



**Figure 4.30 :** Estimation de l'échelle externe  $l_{ext}$  de la cascade multiplicative par la méthode macrocanonique appliquée aux moments statistiques: cas d'une image acquise par la bande B8, le 21 octobre 2016.

	<i>Macro</i>			<i>Micro</i>		
	$l_{ext}$	$\alpha$	$C_1$	$l_{seg}$	$\alpha$	$C_1$
<b>B2</b>	360	1,80	0,13	340	1,81	0,12
<b>B8</b>	430	1,41	0,10	410	1,41	0,10

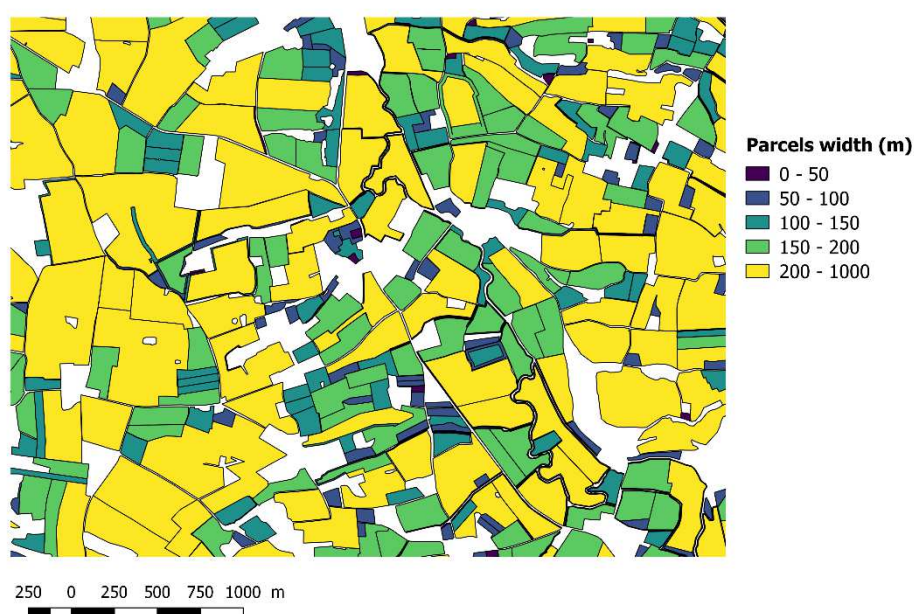
*Tableau 4.5 : Comparaison des échelles externes  $l_{ext}$  et de rupture  $l_{seg}$  (en mètres) estimées respectivement à partir des méthodes macro- et microcanoniques pour les bandes B2 et B8 (21 octobre 2016). Les paramètres universels macro ont été estimés à partir de moments calculés sur la gamme [10 - 160] m, les paramètres micro pour la gamme [10 - 320] m.*

#### 4.4.2.2 La parcelle comme échelle limite entre deux régimes

Suivant cette analyse, la surface observée présente donc un comportement multifractal certain pour les *fines échelles (gamme II)*, alors qu'un comportement multi-échelle plus "simple" (monofractal) serait observé sur les *larges échelles (gamme I)*. Pour identifier l'origine des différences de propriétés multi-échelles entre ces régimes, nous avons comparé nos résultats aux informations que nous avons de la surface, et plus particulièrement sur sa structure spatiale. La zone que nous étudions ici est principalement composée de parcelles agricoles, qui impactent significativement l'hétérogénéité spatiale de la surface. Leur agencement sur le territoire ne suit pas de logique particulière (alignement, regroupement...) et les délimitations des parcelles sont globalement linéaires, créant ainsi des polygones sans forme géométrique remarquable. En revanche, nous avons constaté que, de manière générale, les parcelles couvraient des zones dont l'aire était relativement proche d'une parcelle à l'autre.

Plus particulièrement, la majorité des parcelles de notre zone d'étude révèlent une aire comprise entre 0.3 et 130 ha, correspondant à une largeur de parcelle (étendue estimée en supposant nos surfaces carrées) d'environ 50 à 1000 m. Cela a pu être identifié grâce au Registre Parcellaire Graphique (RPG) de l'année 2016, permettant d'avoir accès à la délimitation, à la surface au sol et au type de cultures de l'ensemble des parcelles agricoles du département du Gers. De ces données, nous en avons déduit une largeur moyenne de parcelle située vers les 170 m. La figure 4.31 ci-dessous présente un exemple de RPG pour une partie de notre zone d'étude, pour lequel ont été classées les parcelles en fonction de leur étendues. Nous observons un nombre important de parcelles dont les largeurs caractéristiques sont

comprises entre 100 m et 1 km (surfaces en bleu clair, vert et jaune). Bien que les parcelles révèlent des structures assez différentes, de formes plus ou moins allongées, voire même avec des "bords" arrondis, le découpage plus ou moins systématique qu'elles génèrent sur le territoire pourrait être à l'origine de la rupture d'échelle observée dans nos résultats. **De cette manière, le régime *fine échelle* observé sur la *gamme II* serait le reflet de la variabilité *intra-parcelle* régie par des processus physiques et biophysiques multifractals reliés aux cultures (humidité du sol, végétation...), alors que le régime *large échelle* de la *gamme I* représenterait la variabilité *extra-parcelle* issue de l'agrégation de plusieurs processus présents à des échelles inférieures et dont l'ensemble ne présenterait pas de propriétés multifractales particulières.**



**Figure 4.31 : Classification des parcelles agricoles en fonction de leur surface estimée selon le Registre Parcellaire Graphique de l'année 2016. Les données représentées ici correspondent à une zone de  $\sim 3 \times 3 \text{ km}^2$  extraite dans notre région d'étude globale. Les largeurs de parcelles ont été calculées à partir des aires en approximant celles-ci à des surfaces carré.**

Nous allons voir maintenant comment la structure spatiale des surfaces agricoles ainsi que leur dynamique au cours des saisons pourrait expliquer le cycle saisonnier observé dans nos résultats.

#### 4.4.2.3 Une dynamique saisonnière liée aux cycles de cultures

L'analyse multifractale réalisée date par date sur les réflectances de surfaces nous a permis d'identifier sur la gamme *fine échelle (II)* un cycle saisonnier des propriétés d'échelle. D'une part, les réflectances acquises dans le proche infrarouge révèlent un comportement multi-échelle particulier durant la saison d'automne. En effet, à cette période nous avons observé une diminution des paramètres  $\beta$ ,  $H$  et  $\alpha$ . Par rapport au reste de l'année, cela montre que le signal acquis en automne serait moins autocorrélé, de nature presque conservative (au sens d'une intégration fractionnaire presque nulle) et présenterait moins de multifractalité que pour les autres saisons. Ainsi, à cette période, les propriétés multifractales semblent s'éloigner du comportement moyen de la *gamme II*, et auraient tendance à se rapprocher de celui de la *gamme I* – présentant des propriétés multi-échelles moins complexes. D'autre part, pour les signaux acquis dans le visible et le moyen infrarouge, un changement particulier des propriétés fractales est détecté cette fois-ci au printemps, avec une augmentation des paramètres  $\beta$ ,  $H$  et  $C_1$  pour le mois de mai. Durant cette période, le signal acquis paraît alors plus autocorrélé, plus lisse, et plus dispersé que pour le reste de l'année.

**Par conséquent, cette dynamique temporelle semble montrer que le passage des périodes de mi-saison (automne, printemps) à saison (hiver, été) modifierait significativement la structure spatiale de la surface. Notre hypothèse serait que cette évolution soit liée au cycle de récolte et de semis des cultures, ayant lieu durant les périodes de mi-saison.** L'évolution des cultures, avec notamment les transitions entre les cultures d'hiver et les cultures d'été, expliquerait le cycle que nous détectons. De plus, cela serait en accord avec l'interprétation des deux régimes correspondant aux comportements *intra-* et *extra-parcelle* : le premier étant directement lié à la dynamique des cultures, il présenterait donc un cycle saisonnier, alors que le second régime ne suivrait pas de dynamique particulière (ce que nous observons dans nos résultats).

L'impact des cultures pourrait également expliquer la nature inversée des cycles entre les comportements du proche infrarouge et du visible/moyen infrarouge. En effet, les réflectances acquises dans le proche infrarouge, étant très sensibles à la végétation, devraient présenter plus de variabilité spatiale lorsque les cultures sont bien développées, donc pour des périodes situées entre les phases de récolte et de semis. Si l'on prend l'exemple du maïs qui est une des cultures majoritairement présentes dans le Sud-Ouest, la phase de récolte a lieu habituellement entre les mois d'août et novembre. Cela correspond à la chute que nous observons sur les paramètres multi-échelle estimés pour la bande B8. Ainsi, une phase de récolte correspondrait à une perte d'hétérogénéité spatiale dans ces longueurs d'onde, révélant un signal plus pauvre et moins structuré que lors d'une phase de croissance de la végétation. De plus, la chute progressive des paramètres (début de diminution observée à

partir du mois d'août) peut s'expliquer d'une part par l'étalement des phases de semis entre août et novembre (selon le calendrier de chaque agriculteur), et d'autre part par la phase de sénescence précédant la récolte et contribuant à réduire la capacité de la végétation à réfléchir le rayonnement solaire (moins de chlorophylle).


A l'inverse, les réflectances du visible se comportent différemment en étant sensibles à d'autres éléments de la surface tels que les routes, le bâti, ou encore le sol nu qui apparaît une fois les récoltes achevées. Ainsi, à mi-saison, lorsque la végétation vient tout juste d'être semée, la surface présente plus de variabilité spatiale dans le domaine du visible que dans celui du proche infrarouge. De plus, nous avons vu que le même cycle était observé dans le moyen infrarouge. A cette longueur d'onde, le capteur est sensible à l'humidité contenue dans le sol et dans la végétation. En effet, nous avons constaté que les paramètres multi-échelles de l'indice d'humidité du sol estimé à partir des bandes B11 et B12 suivaient la même dynamique temporelle. Comme cela a été présenté dans le chapitre précédent, la variabilité spatiale de l'humidité du sol dépend de plusieurs facteurs environnementaux (topographie, propriétés du sol, précipitations, végétation...), présents à différentes échelles spatiales. Ainsi, il se pourrait que le pic de valeur détecté au printemps sur les paramètres d'échelle de l'indice d'humidité soit lié aux précipitations qui sont généralement importantes à cette saison dans le Sud-Ouest. De plus, pour les échelles inférieures à la dizaine de kilomètres, la variabilité spatiale de l'humidité du sol est essentiellement gouvernée par les processus d'écoulement ou d'infiltration, qui sont reliés aux propriétés du sol. Cela serait une explication possible à la similitude entre les cycles des paramètres d'échelle de l'indice d'humidité et celui des paramètres des bandes du visible qui dépendraient dans les deux cas de la structure spatiale du sol à ces échelles.

#### 4.4.2.4 Des gammes d'échelles qui évoluent selon la dynamique de la surface

Pour approfondir cette interprétation, nous nous sommes intéressés de plus près au comportement observé à partir de la bande du proche infrarouge, présentant les variations les plus marquées. En plus de la dynamique détectée sur ses paramètres multi-échelles, **de fortes variations peuvent s'observer sur les bornes délimitant les gammes d'échelles, et notamment sur la position de la rupture R1** (fig.4.25.a). Pour illustrer ce phénomène, nous avons comparé les spectres estimés pour la bande B8 à deux dates distinctes (fig.4.32) : l'une en été (10 juillet) et l'autre en automne (21 octobre). Pour ces spectres, la rupture *fine échelle* R2 a été estimée vers 35 m dans les deux cas, confirmant son origine "instrumentale" (section 4.4.1). En revanche, deux ruptures R1 différentes ont été obtenues : à 340 m pour le spectre de juillet (courbe rouge), et à 72 m pour octobre (courbe verte). Il semblerait que la rupture R1 de juillet se déplace vers les fines échelles en octobre, se combinant avec R2. Ainsi, ces résultats semblent montrer que de deux régimes d'échelle en été nous passerions à un seul régime en automne. Pour le 21 octobre, ce régime semble présent sur une gamme d'échelles




proche de la gamme globale fournie par nos données [72 m – 41 km], et présentant un spectre dont la pente devient inférieure à 1. **De cette manière, le mois d’octobre révélerait un comportement multi-échelle défini sur un seul régime, qui serait caractérisé par un mélange des propriétés fractales des gammes I et II.** Une interprétation pourrait être que la diminution de complexité spatiale à cette période de l’année (liée aux phases de récolte) entrainerait un rapprochement des comportements multi-échelles des processus présents dans la *gamme I* et de ceux présents dans la *gamme II*.



**Figure 4.32 : Spectres de puissance des réflectances de surface acquises en été (10 juillet) et automne (21 octobre) 2016 par la bande du proche infrarouge B8.**

Une analyse similaire peut être faite à partir des fonctions de structure estimées à ces mêmes dates et pour la même bande (fig.4.33). Comme pour les spectres, la rupture se déplace vers les *finer échelles* lorsque l’on se situe en octobre. Ici, ce phénomène est d’autant plus marqué si l’on considère les fluctuations verticales  $\Delta R_x$  au sein de l’image analysée (courbe verte avec deux ruptures sur le graphe). De plus, si l’on se focalise sur ces fluctuations  $\Delta R_x$ , il semblerait que la rupture centrale de juillet (480 m) laisse en fait place à deux ruptures en octobre : une *fine échelle* à 71 m (comparable à celle obtenue pour le spectre d’octobre), et une *large échelle* à 1 km. Ainsi, un régime *central* de pente négative apparaîtrait pour la date d’octobre, en particulier pour la fonction de structure obtenue selon la direction verticale de l’image. Cette différence de comportement entre les deux directions se vérifie notamment par la différence entre les pentes  $H_x$  et  $H_y$  qui est plus importante en octobre ( $\Delta H = 0.13$ ) qu’en juillet ( $\Delta H = 0.03$ ), pour la gamme [70 – 480] m. En Annexe N, nous montrons une analyse plus détaillée de l’anisotropie présente dans les réflectances Sentinel-2, en particulier

pour la bande B8 : les fluctuations et les paramètres  $H$  correspondant ont été estimés pour une multitude de direction, et selon la méthode des différences (cf. section 2.3.2.2). Ces résultats ont confirmé que la bande B8 présentait des propriétés anisotropes plus marquées en automne qu'en été, phénomène qui ne s'observe pas sur les bandes du visible par exemple.



*Figure 4.33 : Fonctions de structure de Haar estimées à partir des réflectances de surface acquises en été (10 juillet) et automne (21 octobre) 2016 par la bande du proche infrarouge B8.*

Une autre remarque vis-à-vis de ces fonctions de structure peut être faite sur la position des valeurs maximales. Comme nous l'avons observé sur les comportements moyens en section 4.3.1.2, les courbes des fonctions de structure révèlent un maximum de fluctuation  $\Delta R_{max}$  qui paraît positionné à une échelle proche de l'échelle de séparation des deux régimes (rupture  $R1$ ). Ici, cela semble se confirmer pour le 10 juillet : nous obtenons des maxima à 400 m ( $\Delta R_X$ ) et 420 m ( $\Delta R_Y$ ), contre 480 m pour la rupture détectée par segmentation. Pour le 21 octobre, le maximum obtenu depuis la fonction de structure horizontale (Y) se situe à 240 m, ce qui est proche des 370 m estimés par segmentation. Pour l'axe vertical, le maximum semble correspondre à la position de la rupture qui apparaît aux *fines échelles*. Ainsi, ces maxima semblent marquer d'une certaine manière la transition entre les deux régimes d'échelle, et suivre leur évolution saisonnière. Si l'on suit l'explication proposée précédemment présentant la transition d'échelle détectée comme la limite des variabilités *intra-* et *extra-parcelle*, **ces résultats signifieraient que le pic de variation présent dans les réflectances se situerait au niveau de l'échelle des parcelles**. Ainsi, on observerait au sein des parcelles une augmentation des fluctuations avec l'échelle ( $H$  positif), et une diminution de


ces fluctuations à des échelles plus larges que la parcelle. De plus, l'anisotropie que nous détectons dans le proche infrarouge au mois d'octobre pourrait s'expliquer par les phases de récolte ou de semis qui structureraient la surface dans une direction plutôt qu'une autre (rangs et inter-rangs identifiables au sein de la parcelle à ces périodes). Cela corroborerait donc le lien qu'il peut y avoir entre l'évolution de la surface et l'évolution des régimes d'échelle au cours de la période, à la fois au niveau des variations des propriétés statistiques spatiales (mono/multifractal, isotrope/anisotrope) mais aussi de la position des gammes et transitions d'échelle.

#### 4.4.2.5 Le lien entre occupation du sol et propriétés multi-échelles : tests sur d'autres types de surface

Pour confirmer cette interprétation, nous avons cherché à analyser et à comparer le comportement multi-échelle de surfaces présentant des caractéristiques différentes. En particulier, nous avons étudié les spectres de puissance de trois surfaces parmi les six décrites en section 4.4.1 pour lesquelles l'occupation du sol est différente : nous avons choisi les surfaces *forests*, *urban* et *crops south* (pour rappel *crops south* est notre zone d'étude de référence). La figure 4.34 présente les spectres obtenus à partir des réflectances acquises pour ces surfaces dans la bande du proche infrarouge (B8), durant la saison d'été. Les images *forests* et *crops south* ont été acquises à la même date, soit le 10 juillet. Pour la surface *urban*, l'image sélectionnée correspond à la date du 23 juin en raison du nombre trop important de nuages présents le 10 juillet. D'une part, nous constatons que le comportement de la surface *urban* se détache de celui des autres surfaces : un spectre peu pentu ( $\beta = 0.75$ ) est obtenu sur une large gamme d'échelles comprises entre l'échelle maximale et une rupture *fine échelle* ( $R2$ ) détectée à  $\sim 40$  m. **Cette surface semble donc présenter une loi d'échelle répartie selon un seul régime d'échelle et caractérisée par une faible autocorrélation spatiale.** Cela peut s'expliquer par la part importante qu'occupent les sols artificiels (bâti, routes...) dans les zones urbaines, dont la structure et l'agencement dans l'espace ne présentent pas de propriétés multifractales particulières à ces échelles-là (d'autant plus lorsqu'ils sont observés dans le proche infrarouge).

D'autre part, la surface *forest* présente un comportement similaire à la surface *crops south* sur des échelles inférieures à 300 m : les spectres révèlent sur cette gamme des pentes spectrales proches ( $\beta \approx 1.5$ ) et une rupture  $R2$  estimée à  $\sim 35$  m. Néanmoins, bien que les deux spectres soient tous les deux moins pentus sur les *larges échelles* ( $\beta \approx 0.2$ ), la transition entre les deux régimes ne se situe pas au même endroit. En effet, le spectre *crops south* révèle une rupture  $R1$  positionnée à 340 m, alors que le spectre *forest* présente une rupture  $R1$  située à environ 1 km. **Ainsi, ces surfaces semblent être toutes les deux caractérisées par deux régimes d'échelle, aux mêmes propriétés fractales d'une surface à l'autre, mais pour lesquels la zone de transition ne se situe pas à la même échelle spatiale.** Il semble alors que

la surface *forest* présente également un régime *fine échelle* aux propriétés multi-échelles complexes (*gamme II*) – probablement dû à la présence de végétation (principalement d’arbre ici) – mais pour lequel l’initialisation des cascades multifractales (échelle externe de la cascade) se fait à une échelle plus grande que celle observée sur notre zone d’étude de référence. Pour comprendre l’origine de ces différences de gamme d’échelles, nous avons analysé l’occupation du sol de la zone *forests*. Plus de la moitié de la zone est occupée par de vastes étendues de forêts (conifères et une minorité de feuillus) pour lesquelles l’aire vaut entre 100 et 300 ha, et entre lesquelles sont insérées quelques parcelles agricoles (dont l’aire moyenne vaut  $\sim 10$  ha). Ainsi, le découpage de la surface est donc moins dense que pour une surface essentiellement composée de cultures. Les zones dont l’occupation du sol est globalement homogène dans l’espace (que l’on appellera ici "entités") sont plus grandes que pour la surface *crops* : ici l’échelle caractéristique de ces entités est comprise entre 1 km et 3 km, et correspond bien à la rupture *R1* observée sur le spectre.



**Figure 4.34 : Spectres de puissance correspondant aux réflectances des surfaces urban, forests et crops south, acquises en été 2016 par la bande du proche infrarouge B8.**

#### 4.4.2.6 Simulation simplifiée d’une surface agricole

Afin de vérifier si les explications précédentes sont réalistes, j’ai tenté de reproduire par simulation un exemple de surface agricole qui aurait les mêmes propriétés multi-échelles que les données S2 étudiées. Pour cela, j’ai simulé un champ multifractal en appliquant le modèle des Multifractales Universelles (méthode décrite en 2.3.1), auquel j’ai combiné une image contenant les délimitations des parcelles agricoles obtenues à partir du RPG-2016 de la zone d’étude *crops south* (fig.4.35.a). Le champ multifractal a été généré en définissant les

valeurs des paramètres universels du modèle à  $\alpha = 2$ ,  $C_1 = 0.1$  et  $H = 0.3$ , correspondant aux valeurs obtenues pour la bande B2 sur la *gamme II* (comportement moyen). La méthode de combinaison consiste simplement à ajouter la texture spatiale engendrée par les parcelles agricoles sur l'image du champ multifractal simulé. Cependant, pour reproduire une texture plus réaliste, les entités (objets "parcelles") ont été préalablement regroupées en six classes : une même valeur de pixel comprise entre les valeurs min et max du champ initial, soit 0 et 1, a été affectée pour chacune de ces classes. Ces dernières ont été définies en fonction de l'aire des entités : les parcelles ont été regroupées en classes d'objets dont l'aire est comprise dans un intervalle prédéfini. Ici, ces intervalles ont été définis à partir des quantiles des aires, de manière à avoir le même nombre d'objets dans chaque classe. Bien que cette classification ne corresponde aucunement à la réalité, elle permet d'une certaine manière, de reproduire les différences d'intensités de réflectances en fonction du type de sol (différents types de culture, sol nu, forêt, etc.) que l'on peut observer sur les données réelles (fig.4.35.b). **Ainsi, la surface finale que j'ai générée ( $i_{simu}$ ) est donc basée sur une cascade multiplicative intégrée ( $i_{MF}$ ) présente à toutes les échelles de l'image, mais à laquelle se rajoute la texture spatiale des parcelles agricoles ( $offset_{parcelle}$ ), telle que :**

$$i_{simu} = i_{MF} + offset_{parcelle}$$

4.13


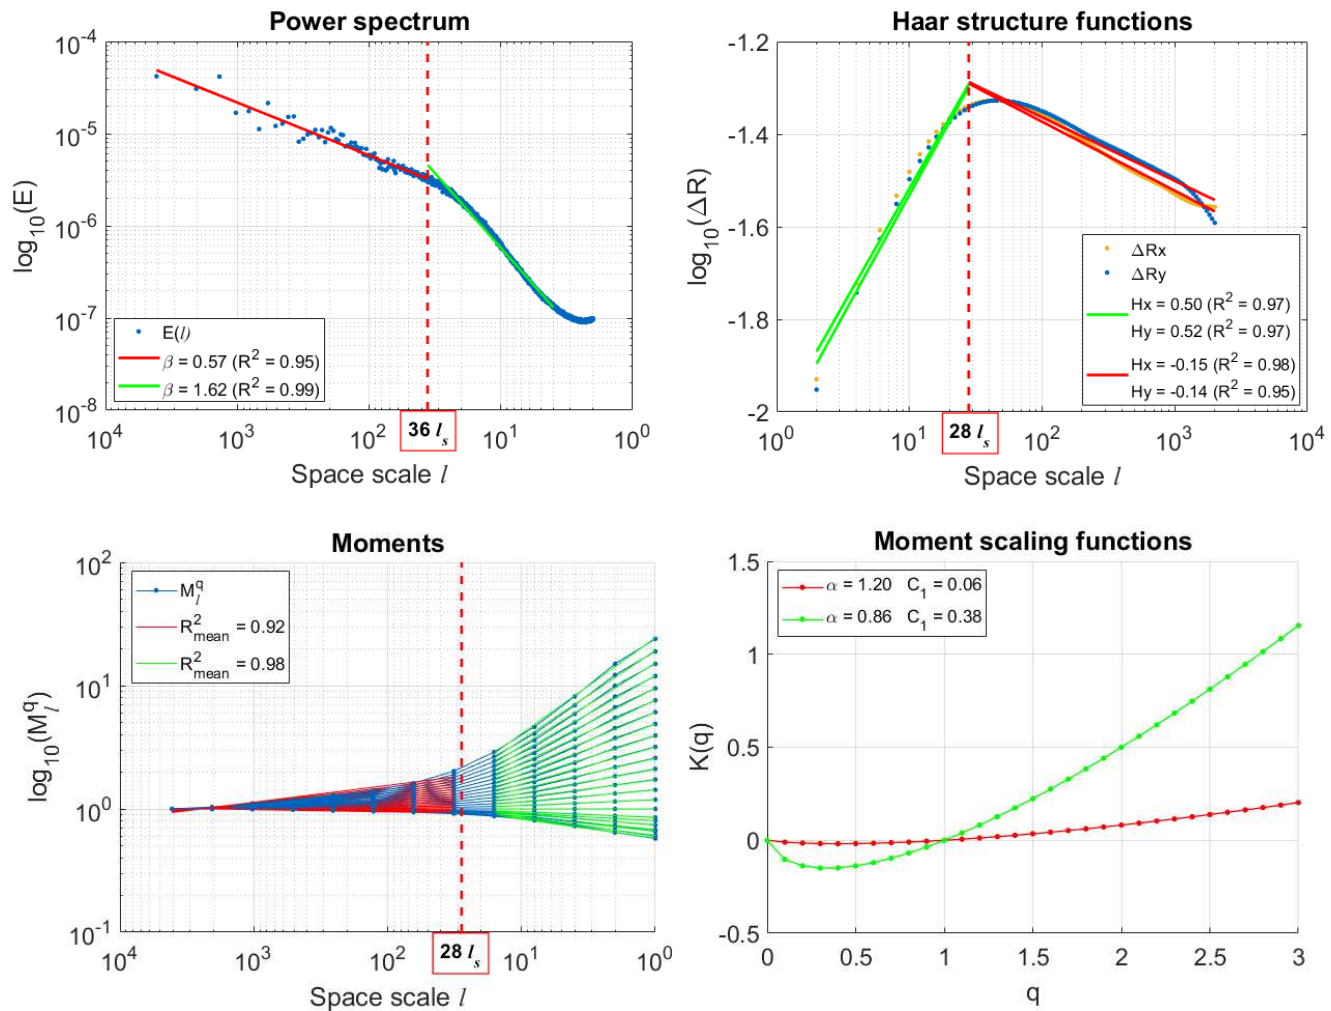


Figure 4.35 : Données simulées et réelles de réflectances de surface correspondant à la zone d'étude (Gers, tuile 30TYP). La simulation a été obtenue par combinaison d'un champ multifractal et du RPG de l'année 2016.

Les graphes de la figure 4.36 représentent les spectres, fonctions de structure de Haar et moments statistiques obtenus pour la surface que nous avons simulée, ainsi que les paramètres multi-échelles correspondants. **Nous constatons que deux régimes sont bien présents pour chacun des estimateurs statistiques**, avec une rupture d'échelle  $R1$  détectée par segmentation à  $l = 36 l_s$  pour le spectre, et  $l = 28 l_s$  pour les fonctions de structure et les moments (ici  $l_s$  a été fixée à 1 pixel pour la simulation). Cette rupture semble donc située à quelques dizaines d'échelles supérieures à l'échelle la plus fine  $l_s$ , ce qui est comparable à nos résultats obtenus à partir des données S2. De plus, les deux régimes semblent également présenter des comportements proches de ceux observés sur les *gammes I et II* de nos produits S2, du moins en termes d'allure des courbes. En effet, nous obtenons une pente spectrale inférieure à 1 et un paramètre  $H < 0$  à *large échelle (gamme I)*, alors qu'une pente spectrale supérieure à un 1 et un paramètre  $H > 0$  sont estimés à *fine échelle (gamme II)*. L'analyse des moments statistiques présente également des paramètres universels distincts d'une gamme à l'autre : le paramètre  $\alpha$  est plus grand à *large échelle*, alors que  $C_1$  révèle une valeur bien plus petite sur cette gamme que sur la gamme *fine échelle*. Notre simulation retranscrit donc bien le comportement en deux gammes d'échelle des produits S2, avec effectivement un comportement multifractal marqué et complexe à *fine échelle*, et un comportement *large échelle* éventuellement moins complexe. En revanche, cette simulation ne permet pas d'obtenir un comportement strictement identique à celui des réflectances, qui se voit sur les deux gammes à travers les faibles valeurs de  $\alpha$  ( $< 1.5$ ) ou les valeurs de  $H$  qui sont significativement différentes des valeurs "réelles". Ces différences peuvent être liées à la manière dont nous avons classé les parcelles pour simuler la texture de l'image qui ne correspond pas à la réalité. **Tout de même, nous avons mis en évidence un lien certain entre le découpage de la surface par les parcelles agricoles et la présence de deux régimes – dont l'échelle de transition est effectivement proche de l'échelle moyenne des parcelles.**





**Figure 4.36 : Estimateurs statistiques et paramètres multi-échelles obtenus à partir des données simulées de réflectances de surface (fig.4.35.a).**

Dans cette partie discussion, nous venons de proposer des explications physiques aux comportements d'échelle des produits S2. D'une part, la rupture *fine échelle* détectée sur les spectres serait de nature instrumentale, engendrée par le système optique embarqué sur le satellite. Plus particulièrement, la fonction de transfert de modulation serait à l'origine de cet artefact, qui modifierait les propriétés statistiques du signal acquis près de la résolution du capteur. D'autre part, le comportement en deux régimes d'échelles serait, quant à lui, directement en lien avec la structure spatiale de la surface. Ce comportement mettrait en évidence une variabilité *intra-parcelle* aux propriétés multifractales et fortement liée à la dynamique saisonnière, et une variabilité *extra-parcelle* sans propriétés multifractales particulières.

## 4.5 Conclusion

L'étude de l'hétérogénéité des surfaces continentales est une tâche délicate en termes de techniques de traitements d'image, en particulier due à l'effet combiné de facteurs naturels et anthropiques présents à différentes échelles spatiales et différentes longueurs d'onde. Parmi diverses techniques d'analyse spatiale, les méthodes basées sur l'étude des propriétés fractales et multifractales se sont révélées avantageuses pour définir la complexité des réflectances de surfaces acquises par capteurs optiques. Au cours des trente dernières années, ces méthodes ont permis de mettre en évidence certaines caractéristiques des réflectances comme l'impact de la longueur d'onde d'acquisition sur la complexité spatiale, ainsi que l'effet de l'occupation du sol sur l'hétérogénéité. De plus, des modèles stochastiques complexes utilisés initialement dans le domaine de la turbulence ont prouvé que les surfaces continentales présentaient des propriétés fractales et même multifractales pour des échelles comprises entre le mètre et la dizaine de kilomètres.

Dans cette étude, nous avons appliqué le modèle des Multifractales Universelles pour analyser le comportement multi-échelle de réflectances de surfaces et indices optiques Sentinel-2 acquis sur la région Sud-Ouest de la France, et corrigés des effets de l'atmosphère par la chaîne de traitement MAJA. Grâce à cette chaîne de traitement, nous avons pu étudier une série d'images sans nuages sur l'ensemble de l'année 2016. Cela nous a permis d'accéder à la dynamique des propriétés multi-échelles des réflectances de surface, ce qui, à notre connaissance, n'avait pas encore été exploré à ce jour en raison de l'impact non négligeable des nuages sur les données optiques. A partir de ces données, nous avons pu mettre en évidence la présence de deux régimes d'échelles avec des comportements multifractals distincts. Pour des échelles supérieures au kilomètre, nous avons observé un comportement fractal peu complexe et assez éloigné des comportements multifractals couramment détectés dans la littérature (topographie, pluie, nuages). Pour les échelles inférieures au kilomètre, nous avons en revanche observé une autocorrélation et une complexité plus élevée dans nos données, traduisant la présence de processus multifractals "non-conservatifs" comparables à la littérature (turbulence). De plus, un cycle saisonnier des paramètres multi-échelles a été révélé pour le régime *fine échelle*, alors qu'aucun comportement temporel particulier n'a été remarqué pour le régime *large échelle*.

Nous avons pu montrer que la présence de ces régimes pouvait s'expliquer par la structure caractéristique des surfaces agricoles, qui sont prépondérantes dans notre zone d'étude. D'une part, le régime *fine échelle* représenterait la variabilité *intra-parcelle*, régie par des processus physique et biophysique multifractals en lien avec la dynamique des cultures (humidité, végétation...), engendrant une évolution des propriétés d'échelle au cours de la saison et expliquant ainsi le cycle saisonnier présent dans cette gamme d'échelles. D'autre part, le régime *large échelle* reflèterait la variabilité *extra-parcelle*, issue du regroupement de

divers processus multifractals *fine échelle*, et dont l'agrégation ne présenterait pas de propriétés multifractales ni de comportement temporel particuliers. L'échelle de transition entre les régimes correspondrait donc à la taille moyenne des parcelles agricoles pour cette région. Nous avons montré que pour d'autres types de surfaces en France (occupation du sol différente), le même comportement en deux gammes était observé mais avec une transition d'échelle positionnée différemment.

**Ainsi, ces travaux ont montré l'apport de l'analyse multifractale pour caractériser la variabilité spatiale des surfaces continentales, et en particulier l'impact de l'occupation du sol et sa dynamique temporelle sur l'évolution des régimes d'échelle. De plus, cette analyse a permis de mettre en évidence les limites de performance du capteur optique MSI de Sentinel-2.** En effet, à partir des spectres de puissance, une altération du signal a été observée sur les *fines échelles* et ce indépendamment de la surface observée. Ce phénomène serait généré par la fonction de transfert du système optique qui affecterait les hautes fréquences de l'image acquise. La rupture détectée aux fines échelles correspondrait éventuellement à la résolution effective du capteur, au-delà de laquelle les propriétés fractales *fine échelle* de la surface observée ne seraient pas correctement transmises.

Des travaux supplémentaires seront nécessaires pour expliquer précisément ces résultats. Pour confirmer l'impact de l'occupation du sol sur les régimes, il faudrait améliorer la simulation proposée en intégrant des données d'occupation du sol réalistes, auxquelles pourraient être affectées des cascades simulées différentes selon le type de sol (paramètres universels différents d'un type de surface à l'autre). On pourrait également faire évoluer la structure des parcelles agricoles (plus ou moins larges, de formes différentes, etc.) et ainsi observer l'impact sur les propriétés d'échelles (modification de la position de la rupture, création d'anisotropie, etc.). De plus, afin de confirmer le lien entre le cycle saisonnier et les rotations de cultures, nous pourrions introduire un aspect temporel dans ces simulations et utiliser des cartes d'occupation du sol représentatives de chaque saison. Ainsi, nous pourrions par exemple vérifier l'impact des phases de semis ou de récolte d'un type de culture sur la dynamique des propriétés multi-échelle des réflectances du proche infrarouge.

En ce qui concerne l'effet de la fonction de transfert du capteur sur les réflectances, le modèle appliqué ici pourrait être approfondi en intégrant d'autres facteurs influant sur cette fonction (déplacements de charges, température). Il serait aussi intéressant de pouvoir établir précisément pourquoi la rupture *fine échelle* se situe à  $\sim 4 l_s$  (relation mathématique) et éventuellement proposer une méthode qui corrigerait cet artefact. Ici, nous pourrions par exemple appliquer un algorithme de désagrégation stochastique qui consisterait à prolonger sur les échelles "impactées" ( $l < 4 l_s$ ) la cascade multiplicative présente aux échelles supérieures ( $l > 4 l_s$ ).

Enfin, de manière plus générale, cette étude pourrait être approfondie en analysant les propriétés multifractales d'autres données satellites de même type (Landsat-8, Venus), acquises dans des bandes comparables et sur la même région. Ainsi, cela pourrait confirmer la présence des deux régimes et du cycle saisonnier (indépendant à priori du capteur), et vérifier si la même altération des *fines échelles* serait observée pour ces capteurs optiques. En effet, si le même modèle de fonction de transfert s'avère applicable sur ces autres capteurs, cela confirmerait l'existence d'une résolution effective pour les capteurs optiques. La connaissance de cette résolution pourrait être utile à la préparation de futures missions spatiales afin de déterminer les limites des capteurs en termes de propriétés multi-échelles.

## 5 Conclusion générale et perspectives

---

L'objectif de cette thèse était de proposer et d'appliquer une méthode permettant de décrire et de mieux comprendre les comportements de variables de surface, en se basant sur le formalisme des multifractales. Pour cela, différents produits de surface acquis par satellite ont été analysés au moyen du modèle des Multifractales Universelles. Deux cas d'étude ont permis de répondre à cet objectif : l'analyse de l'algorithme DisPATCH appliqué en Australie pour la période Juin-Décembre 2010 (Neuhauser et al., 2019), et l'étude de données multispectrales Sentinel-2 acquises sur la région Sud-Ouest de la France durant la période Janvier-Décembre 2016.

### 5.1 L'algorithme DisPATCH en Australie

#### 5.1.1 Synthèse des résultats

Dans ce premier cas d'étude, nous avons étudié et comparé les propriétés multifractales des produits d'entrée et de sortie de l'algorithme de désagrégation d'humidité du sol DisPATCH. Les produits d'entrée de DisPATCH (indice de végétation et température de surface MODIS, humidité du sol SMOS) ont révélé des propriétés multifractales sur l'ensemble de la gamme d'échelles étudiée. En revanche, un comportement spécifique a été observé pour l'humidité désagrégée par DisPATCH. Une rupture d'échelle a été détectée à une dizaine de kilomètres sur les spectres puissance, fonctions de structure et moments statistiques.

Pour expliquer ce comportement de l'humidité DisPATCH, nous avons proposé deux arguments possibles. Tout d'abord, une interprétation plus physique indiquerait que la rupture observée serait le reflet de processus hydrométéorologiques non-linéaires tels que les précipitations, l'évapotranspiration ou l'infiltration agissant à différentes échelles spatiales et modulés par les propriétés du sol et la végétation. Une deuxième explication serait plus algorithmique et directement liée aux traitements des différents produits utilisés et générés au sein de l'algorithme DisPATCH. En particulier, cette rupture pourrait provenir en partie des produits d'entrée LST MODIS et en partie des artefacts de traitement liés à la combinaison de plusieurs produits définis par différents espacements de grille.

A ce stade, ces résultats ne permettent pas de déterminer de manière sûre lequel de ces deux facteurs serait à l'origine du comportement en deux gammes de l'humidité désagrégée. Néanmoins, une hypothèse serait que les deux facteurs pourraient affecter de manière conjointe les propriétés multi-échelles de l'humidité désagrégée. En effet, nous pensons qu'une rupture située à une échelle proche de la résolution de l'humidité SMOS

pourrait être initialement produite par les artefacts de traitements, et que cette même rupture serait plus ou moins amplifiée à travers l'algorithme selon les conditions saisonnières, entraînant le déplacement de la rupture d'échelle au cours de la période vers des échelles plus fines.

De manière générale, nous avons pu observer dans cette étude le comportement multi-échelle de diverses variables de surface interagissant au sein d'un algorithme de désagrégation basé sur un modèle physique d'évaporation. D'une part, cela nous a permis d'accéder à la variabilité spatiale de l'humidité du sol sur une large gamme d'échelles spatiales allant du kilomètre au millier de kilomètres. A notre connaissance, ce travail n'avait pas encore été réalisé à ce jour. D'autre part, nous avons pu comparer les comportements multi-échelles de diverses variables de surfaces et ainsi observer leur lien sur plusieurs échelles spatiales. Ainsi, ce travail a pu apporter certaines réponses quant à l'hétérogénéité spatiale de l'humidité du sol, mais également contribuer à caractériser un algorithme de désagrégation d'une manière originale et complémentaire aux méthodes couramment utilisées.

### 5.1.2 Perspectives

Un certain nombre de travaux sont à entreprendre pour expliquer de manière sûre l'origine du comportement en deux gammes d'échelles de l'humidité désagrégée, en particulier pour déterminer dans quelle mesure chacun des deux arguments proposés affecterait ce comportement.

Dans l'hypothèse d'une origine physique de la rupture, liée aux facteurs environnementaux, il serait intéressant de réaliser une comparaison avec des données auxiliaires fine échelle (~ 1 km) acquises sur notre région d'étude (bassin du Murray Darling). Nous pourrions effectuer une analyse en EOF (ou équivalente) sur les humidités DisPATCH et des données de topographie, teneur en eau de la végétation, composition du sol ([Kim and Barros, 2002b](#)). Cela nous permettrait de montrer que ces variables de surface sont plus ou moins liées selon la gamme d'échelles spatiales et de justifier ainsi la présence des deux régimes sur l'humidité du sol. De plus, étant donnée la dépendance certaine entre précipitations et humidité du sol, nous pourrions vérifier si une telle rupture d'échelle ne se détecterait pas sur des données de pluies mesurées dans la même zone et même période (Juin-Décembre 2010). Enfin, nous avons pu constater que notre comparaison entre les températures de brillance (TB) aéroportées et l'humidité désagrégée n'a pas été concluante : un seul régime d'échelle fut observé sur les TB, au lieu des deux sur l'humidité. Ainsi, une analyse multifractale de réels produits fine échelle d'humidité du sol (aéroportés) permettrait de clarifier l'origine physique ou alors plutôt algorithmique de la rupture. De même, l'analyse de produits DisPATCH obtenus sur une autre zone d'étude apporterait des réponses sur ce comportement. En effet, dans le cas où aucune rupture d'échelle ne serait détectée sur les



produits désagrégés, l'interprétation physique serait donc à privilégier. Une possibilité serait d'étudier les propriétés multi-échelles des produits DisPATCh obtenus par [Merlin et al. \(2013\)](#) sur la région de Catalogne (Espagne) à partir de produits provenant de sources identiques aux nôtres (SMOS et MODIS).

Selon l'hypothèse d'une rupture d'échelle induite par la méthode de désagrégation, il serait pertinent d'analyser le comportement des produits DisPATCh dans d'autres applications de l'algorithme. D'une part, afin de quantifier l'impact des données de température de surface sur les propriétés multi-échelles de l'humidité du sol, il serait intéressant d'analyser les humidités DisPATCh obtenues à partir des produits auxiliaires Landsat-7/8 à 100 m de résolution ([Merlin et al., 2013](#)). Si notre hypothèse est vérifiée, alors une rupture d'échelle serait détectée à la fois sur les produits de température Landsat-7/8 et sur les produits désagrégés, mais éventuellement décalée vers des échelles plus fines que l'échelle de 10 km observée sur MODIS. Sur un plan plus opérationnel, si cet impact est confirmé, les résultats obtenus pourraient aider à définir une échelle spécifique en dessous de laquelle la variabilité générée par le modèle de désagrégation risque de ne pas être aussi fiable qu'elle devrait l'être. D'autre part, récemment [Ojha et al. \(2019\)](#) ont proposé une méthode permettant de limiter les artefacts liés aux données basse résolution sur les images désagrégées d'humidité du sol. Dans leur étude, ils ont appliqué l'algorithme DisPATCh à des données d'humidité du sol SMAP définies à ~ 40 km de résolution, combinées aux données optiques/thermiques Landsat-7/8. La méthode qu'ils proposent est basée sur une fenêtre à moyenne glissante, diminuant la trace des pixels SMAP sur les images finales DisPATCh. Ainsi, cette technique a permis d'augmenter l'efficacité de l'algorithme DisPATCh en améliorant la corrélation spatio-temporelle de l'humidité désagrégée (ici à 100 m) avec des mesures in-situ d'humidité. Il serait intéressant de voir si, d'un point de vue multi-échelle, les propriétés statistiques des données DisPATCh seraient améliorées à large échelle – atténuation de la transition imparfaite à la résolution des humidités d'origine – mais qu'elles ne soient tout de même pas trop affectées aux fine échelles par l'effet de filtrage de la méthode proposée.

Enfin, une piste d'amélioration de l'algorithme DisPATCh serait de combiner l'approche déterministe du modèle initial avec une approche stochastique. En effet, nous pourrions nous inspirer des méthodes de désagrégation fractales qui ont l'avantage de préserver la validité de la distribution de probabilité lors d'un passage des grandes échelles vers les fines échelles. Par exemple, dans l'algorithme DisPATCh, une possibilité serait de proposer un estimateur modifié de la SEE qui serait utilisé dans la désagrégation. Cet estimateur modifié serait calculé en appliquant un filtre 2D sur la SEE d'origine, ce qui reviendrait à effectuer une intégration fractionnaire d'ordre  $\Delta H = H_{recherché} - H_{non-filtré}$ , avec  $H_{recherché}$  et  $H_{non-filtré}$  les paramètres mesurés respectivement à partir des humidités du sol d'origine (larges échelles) et de la SEE non filtrée (pour les échelles inférieures à l'échelle de rupture). De cette manière, la pente spectrale de SEE serait ajustée, comme celle de

l'humidité finale désagrégée. Ainsi, les produits large échelle et fine échelle pourraient être reliés par un degré commun d'intégration fractionnaire, ce qui pourrait contribuer à limiter le comportement en deux gammes d'échelles observé sur le produit désagrégé. En pratique, cette modification ne serait pas évidente à mettre en œuvre car le filtrage devrait être correctement dimensionné afin de n'affecter que les fines échelles, comprises entre l'échelle minimale et l'échelle de rupture. De plus, cette correction modifiant directement la texture de l'image, elle pourrait avoir un impact sur les propriétés physiques de la SEE. Ainsi, un compromis devrait donc être fait entre propriétés "statistiques multi-échelles" ou propriétés "déterministes évaporatives".

## 5.2 Les données Sentinel-2 dans la région Sud-Ouest

### 5.2.1 Synthèse des résultats

Ce deuxième cas d'étude a consisté à analyser le comportement multi-échelle de réflectances de surface et indices optiques acquis par le satellite Sentinel-2 et corrigés des effets de l'atmosphère par la chaîne de traitement MAJA. A partir de ces données, nous avons pu mettre en évidence la présence de deux régimes d'échelles avec des comportements multifractals distincts. Pour des échelles supérieures au kilomètre, nous avons observé un comportement fractal peu complexe et assez éloigné des comportements multifractals couramment détectés dans la littérature (topographie, pluie, nuages). Pour les échelles inférieures au kilomètre, nous avons en revanche observé une autocorrélation et une complexité plus élevée dans nos données, traduisant la présence de processus multifractals "non-conservatifs" comparables à la littérature (turbulence). De plus, un cycle saisonnier des paramètres multi-échelles a été révélé pour le régime *fine échelle*, alors qu'aucun comportement temporel particulier n'a été remarqué pour le régime *large échelle*.

Nous avons pu montrer que ce comportement en deux régimes d'échelles était directement relié à la structure spatiale de la surface, et notamment aux parcelles agricoles. Ce comportement mettrait en évidence une variabilité *intra-parcelle* régie par des processus physiques et biophysiques multifractals en lien avec la dynamique des cultures (humidité, végétation...), et une variabilité *extra-parcelle* issue du regroupement de divers processus multifractals fine échelle, et dont l'agrégation ne présenterait pas de propriétés multi-échelles particulières. L'échelle de transition entre les régimes correspondrait donc à la taille moyenne des parcelles agricoles pour cette région. Nous avons montré que pour d'autres types de surfaces en France (occupation du sol différente), le même comportement en deux gammes était observé mais avec une transition d'échelle positionnée différemment.

Cette analyse a également mis en évidence un comportement d'échelle singulier, présent de manière systématique sur les différents produits optiques : une chute spectrale a été observée près de la résolution du capteur, traduisant une altération du signal mesuré sur les fines échelles et ce indépendamment de la surface observée. Nous avons pu expliquer ce phénomène par l'effet du système d'acquisition des capteurs optiques (fonction de transfert de modulation) qui affecterait les hautes fréquences de l'image acquise.

Ainsi, ces travaux ont montré l'apport de l'analyse multifractale pour caractériser la variabilité spatiale des surfaces continentales, et en particulier l'impact de l'occupation du sol et sa dynamique temporelle sur l'évolution des régimes d'échelle. Cela a été possible notamment grâce à la chaîne MAJA, nous permettant d'étudier une série d'images sans nuages sur l'ensemble de l'année 2016. Cela nous a permis d'accéder à la dynamique des propriétés multi-échelles des réflectances de surface, ce qui, à notre connaissance, n'avait pas encore été exploré à ce jour en raison de l'impact non négligeable des nuages sur les données optiques. De plus, cette étude a fourni un argument théorique de validation quant à l'origine de la chute spectrale souvent observée sur les produits optiques. Cela a permis de mettre en évidence les limites de performance des capteurs optiques, et ainsi de justifier la présence d'une résolution effective en dessous de laquelle les propriétés statistiques des surfaces ne sont pas correctement retranscrites par le capteur.

### 5.2.2 Perspectives

Afin de compléter l'interprétation des régimes d'échelles *intra-parcelle* et *extra-parcelle* observés sur les produits Sentinel-2, nous suggérons d'approfondir notre simulation multifractale d'une surface agricole (fig.4.35). En effet, il serait intéressant d'intégrer des données réelles d'occupation du sol, auxquelles pourraient être affectées des cascades multiplicatives différentes selon le type de sol (paramètres universels différents d'un type de surface à l'autre). Une possibilité serait d'identifier les paramètres  $\alpha$ ,  $C_1$  et  $H$  de chaque type de surface présent dans la zone d'étude (maïs, blé, prairie, sol nu, route, etc.), puis de générer un champ multifractal final  $R_{final}$  issu de la combinaison de plusieurs champs  $R_{surface}$  correspondant chacun à une surface particulières ( $R_{surface} = R_{maïs}$ ,  $R_{surface} = R_{sol\ nu}, \dots$ ). L'agencement spatial des différents champs  $R_{surface}$  se ferait en respectant l'occupation du sol de la région en question. Dans notre cas, nous pourrions utiliser la carte d'occupation des sols du CES OSO (Centre d'Expertise Scientifique Occupation des Sols) correspondant à l'année 2016 pour le département du Gers. De plus, pour compléter cette modélisation multi-échelle des surfaces agricoles, nous pourrions introduire une dimension temporelle aux simulations en utilisant des cartes d'occupation du sol représentatives de chaque saison. Ainsi, nous pourrions par exemple vérifier l'impact des phases de semis ou de récolte d'un type de culture sur la dynamique des propriétés multi-échelles des réflectances du proche infrarouge. De

même, ce travail pourrait être appliqué sur d'autres régions de France aux propriétés de surfaces différentes, montrant l'impact de la structure spatiale (changement de forme et de taille des parcelles d'une région à l'autre) sur les propriétés d'échelles (évolution de la rupture d'échelle, création d'anisotropie, etc.).

Néanmoins, cette méthode resterait spécifique à notre cas d'étude, correspondant à des simulations réalisées à partir de données réelles et donc particulières. Or, une perspective ici serait d'élargir la méthode à des données simulées au moyen d'un modèle de surface. Un candidat idéal pourrait être le modèle de transfert radiatif DART (Discrete Anisotropic Radiative Transfer, <http://www.cesbio.ups-tlse.fr/us/dart.html>). Développé au CESBIO depuis 1992, ce modèle permet de simuler dans le domaine du visible à infrarouge thermique les mesures obtenues par divers types de capteurs satellites (actifs, passifs), pour plusieurs conditions d'acquisition (bandes spectrales, résolutions spatiales...) et différents types de surface (forêt, cultures, routes, etc.). Ces surfaces correspondent à des simulations 2D ou 3D de paysages naturels ou urbains. Une possibilité serait alors de recréer les propriétés radiatives d'une surface continentale, composée d'un ensemble d'éléments naturels (arbres, prairies) et anthropiques (routes, parcelles agricoles). Puis, il serait intéressant de faire évoluer certaines caractéristiques de cette surface, comme la taille des parcelles agricoles ou l'occupation du sol, et d'en observer l'impact sur le comportement multi-échelle des réflectances de surfaces simulées. Ainsi, cette méthodologie permettrait d'apporter un argument théorique de validation quant au lien entre l'occupation du sol et les régimes d'échelles détectés sur les données multispectrales acquises par satellite comme celles de Sentinel-2.

En ce qui concerne la chute spectrale observée près de la résolution du capteur, le modèle multi-échelle que nous avons proposé pourrait être approfondi en intégrant d'autres facteurs influant sur la fonction de transfert de modulation comme les déplacements de charges ou la température. Nous pourrions également appliquer ce modèle à partir de la fréquence de coupure du capteur MSI, afin d'être dans les conditions réelles d'acquisition des données Sentinel-2. Il serait aussi intéressant de pouvoir établir précisément pourquoi la rupture *fine échelle* se situe à  $\sim 4 l_s$  (relation mathématique) et éventuellement proposer une méthode qui corrigerait cet artefact. Ici, nous pourrions par exemple appliquer un algorithme de désagrégation stochastique qui consisterait à prolonger sur les échelles "impactées" ( $l < 4 l_s$ ) la cascade multiplicative présente aux échelles supérieures ( $l > 4 l_s$ ).

Enfin, de manière plus générale, cette étude pourrait être approfondie en analysant les propriétés multifractales d'autres données satellites de même type (Landsat-8, Venus), acquises dans des bandes comparables et sur la même région. Ainsi, cela pourrait confirmer la présence des deux régimes et du cycle saisonnier (indépendant a priori du capteur), et vérifier si la même altération des *finest échelles* serait observée pour ces capteurs optiques. En

effet, si le même modèle de fonction de transfert s'avère applicable sur ces autres capteurs, cela confirmerait l'existence d'une résolution effective pour les capteurs optiques.

### 5.3 Bilan général

Ce travail a permis de mettre en évidence des comportements multi-échelles spécifiques de produits de surface acquis par satellite ou synthétisés par modèle. Nous avons pu constater que ces comportements pouvaient être le reflet de deux types de phénomènes.

**Tout d'abord, ils peuvent être directement reliés aux propriétés physiques de la surface.** Les différents régimes d'échelles que nous avons observés traduisent la présence de processus de surface non-linéaires agissant à différentes échelles spatiales. Dans le cas de l'humidité, sa variabilité spatiale est directement liée aux processus de ruissellement, d'évaporation ou aux précipitations. Ces processus peuvent être modulés par divers facteurs tels que la topographie, la composition et l'occupation du sol. Les parcelles agricoles jouent un rôle important dans la structure spatiale des surfaces, affectant artificiellement les processus de surface, et leur hétérogénéité spatiale.

**Ensuite, ces comportements d'échelle peuvent également refléter l'impact sur les variables de surface des méthodes d'acquisition ou de traitements couramment utilisées en télédétection.** Dans le cas des capteurs optiques, les propriétés statistiques des produits mesurés sont altérées près de la résolution du capteur. De même, les différentes combinaisons de produits satellitaires intervenant dans les modèles de surface ont un impact non désiré à certaines échelles spatiales, modifiant ainsi le comportement multi-échelle des variables de surface synthétisées.

Ces travaux de thèse ont contribué à améliorer notre compréhension des processus de surface et de leur hétérogénéité spatiale. Grâce au modèle des Multifractales Universelles, nous avons pu décrire les propriétés statistiques de variables géophysiques sur plusieurs échelles spatiales. Cette caractérisation pourrait être utile dans les modèles actuels de surface qui prennent peu en compte le comportement multi-échelle, fonctionnant sur des échelles soit locales soit globales. Il serait possible de vérifier si les produits synthétisés par ces modèles respectent les régimes et transitions d'échelles attendues, et dans le cas contraire contraindre les statistiques de ces modèles sur certaines gammes d'échelles. Ainsi, cette étude a montré le potentiel de l'analyse multifractale pour évaluer la fiabilité de produits ou modèles de surface. De par sa généralité, la méthode présentée dans cette thèse pourrait permettre la validation d'autres types de produits, issues de technologies différentes telles que le radar (Sentinel-1), ou définies à très haute résolution comme les données Pléiades. D'un point de vue plus opérationnel, cela pourrait être utile à la préparation de futures missions spatiales afin de déterminer les limites des capteurs en termes de propriétés multi-échelles, et ainsi à

mieux estimer la résolution effective de différents produits dérivés des acquisitions satellitaires.

Enfin, d'un point de vue plus méthodologique, une manière de renforcer l'interprétation des propriétés multi-échelles observées dans cette étude serait d'associer au modèle des Multifractales Universelles une technique alternative et complémentaire basée sur l'entropie informationnelle : *l'entropie multi-échelle* (MSE : Multi-Scale Entropy; [Costa et al., 2002](#); [Silva et al., 2016, 2018](#)). Celle-ci consiste à mesurer l'entropie d'échantillon ([Richman and Moorman, 2000](#)) pour plusieurs niveaux d'agrégation du signal, permettant ainsi d'informer sur l'irrégularité et la complexité du signal sur plusieurs échelles. Initialement développée dans le domaine biomédical pour l'analyse de séries temporelles ([Costa et al., 2002](#)), cette méthode a ensuite été adaptée aux signaux à deux dimensions et a montré son potentiel pour caractériser la texture d'images diverses ([Silva et al., 2016, 2018](#)). De plus, les travaux de [Nogueira \(2017\)](#) ont permis de mettre en évidence le lien entre les propriétés fractales de données géophysiques à une dimension (vitesse du vent) et la MSE. Pour ces données, [Nogueira \(2017\)](#) ont montré que la MSE était reliée à la résolution  $\lambda$  du signal à travers une loi puissance faisant intervenir un exposant  $H'$  comparable au paramètre  $H$  estimé par les fonctions de structure :


$$MSE \approx \lambda^{H'}$$

5.1

Afin de vérifier si ce lien est également présent dans le cas 2D, nous avons appliqué la MSE à des images multifractales simulées pour différentes valeurs du paramètre  $H$ . Les résultats que nous avons obtenus (présentés en Annexe O) ont montré une équivalence entre les pentes estimées à partir de la MSE et les valeurs du paramètre  $H$  utilisées dans la simulation. Ainsi, il semble que l'entropie multi-échelle permette de mettre en évidence certaines propriétés fractales présentes dans les images.

A la suite de ces travaux de thèse, l'entropie multi-échelle pourrait apporter une information physique supplémentaire sur l'origine des transitions d'échelle entre les différents régimes que nous avons pu détecter. Pour illustrer cela, nous avons réalisés quelques tests préliminaires sur les données Sentinel-2. En figure 5.1, nous comparons les MSE estimées à partir des réflectances de surface acquises dans le proche infrarouge (bande B8) pour trois dates distinctes au cours de l'année 2016 : en hiver (4 février), en été (10 juillet) et en automne (21 octobre). A ces trois dates, l'entropie multi-échelle confirme un comportement en deux gammes d'échelles. Pour les *fines échelles* ( $l < 100 \text{ m}$ ), la MSE croît avec l'échelle traduisant une augmentation en fonction de l'échelle du taux d'information créée et ainsi de la complexité du signal. A l'inverse, ce taux diminue pour les *larges échelles* ( $l > 700 \text{ m}$ ). De plus, ces deux régimes semblent séparés par une échelle de transition qui évolue au cours de la période d'étude et qui est associée aux valeurs maximales d'entropie

(flèches noires sur le graphe). Ainsi, ces résultats préliminaires confirment la présence de régimes d'échelle qui évoluent au cours des saisons, et apportent également une information complémentaire sur les propriétés spatiales des surfaces au sein de ces régimes. Si l'on suit l'interprétation proposée précédemment présentant la transition d'échelle détectée comme la limite des variabilités *intra-* et *extra-parcelle*, ces résultats signifieraient que le pic d'entropie présent dans les réflectances (ou du moins dans ce cas précis des réflectances du proche infrarouge) se situerait au niveau de l'échelle des parcelles agricoles. Cette interprétation semble plausible étant donnée l'agencement désordonné des parcelles agricoles, aux formes géométriques aléatoires, générant ainsi dans les réflectances un signal présentant le plus d'incertitude et de complexité à ces échelles-là.



**Figure 5.1 : Entropie multi-échelle estimée à partir des réflectances Sentinel-2 acquises dans le proche infrarouge, les 4 février, 10 juillet et 21 octobre 2016, sur le département du Gers (tuile 30TYP). Pour chaque courbe, les valeurs maximales d'entropie (flèches noires) sont associées aux échelles de transitions entre les deux régimes.**

Cette méthode d'analyse par entropie multi-échelle présente un potentiel certain pour mettre en évidence les comportements d'échelle de variables géophysiques. Néanmoins, il s'agit d'une méthode qui peut engendrer des temps de calculs conséquents, en particulier dans le cas d'images satellites dépassant souvent le million de pixels, la rendant inadaptée pour l'analyse de séries temporelles de produits de télédétection. Cependant, associée au modèle des Multifractales Universelles, l'entropie multi-échelle peut s'avérer être intéressante pour aider à l'interprétation physique des propriétés multifractales préalablement détectées par les spectres, fonctions de structure ou moments statistiques.



# Références bibliographiques

---

- Ackerman, S. A., Strabala, K. I., Menzel, W. P., Frey, R. A., Moeller, C. C., & Gumley, L. E. (1998). Discriminating clear sky from clouds with MODIS. *Journal of Geophysical Research: Atmospheres*, 103(D24), 32141-32157. <https://doi.org/10.1029/1998JD200032>
- Aguado, P. L., Del Monte, J. P., Moratíel, R., & Tarquis, A. M. (2014). Spatial Characterization of Landscapes through Multifractal Analysis of DEM. *The Scientific World Journal*, 2014, 1-9. <https://doi.org/10.1155/2014/563038>
- Akbar, R., & Moghaddam, M. (2015). A Combined Active–Passive Soil Moisture Estimation Algorithm With Adaptive Regularization in Support of SMAP. *IEEE Transactions on Geoscience and Remote Sensing*, 53(6), 3312-3324. <https://doi.org/10.1109/TGRS.2014.2373972>
- Al Bitar, A., Leroux, D., Kerr, Y. H., Merlin, O., Richaume, P., Sahoo, A., & Wood, E. F. (2012). Evaluation of SMOS Soil Moisture Products Over Continental U.S. Using the SCAN/SNOTEL Network. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1572-1586. <https://doi.org/10.1109/TGRS.2012.2186581>
- Albergel, C., Brocca, L., Wagner, W., de Rosnay, P., & Calvet, J. C. (2013). Selection of performance metrics for global soil moisture products : The case of ASCAT product. *Remote Sensing of Energy Fluxes and Soil Moisture Content*, 431-448.
- Alonso, C., Tarquis, A. M., Zúñiga, I., & Benito, R. M. (2017). Spatial and radiometric characterization of multi-spectrum satellite images through multi-fractal analysis. *Nonlinear Processes in Geophysics*, 24(2), 141-155. <https://doi.org/10.5194/npg-24-141-2017>
- AlSuwaidi, A., Grieve, B., & Yin, H. (2017). Spectral-texture approach to hyperspectral image analysis for plant classification with SVMs. *2017 IEEE International Conference on Imaging Systems and Techniques (IST)*, 1-6. <https://doi.org/10.1109/IST.2017.8261496>
- Ameline, M., Fieuzal, R., Betbeder, J., Berthoumieu, J.-F., & Baup, F. (2018). Estimation of Corn Yield by Assimilating SAR and Optical Time Series Into a Simplified Agro-Meteorological Model : From Diagnostic to Forecast. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(12), 4747-4760. <https://doi.org/10.1109/JSTARS.2018.2878502>
- Anderson, M. C., Norman, J. M., Mecikalski, J. R., Otkin, J. A., & Kustas, W. P. (2007). A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing : 2. Surface moisture climatology. *Journal of Geophysical Research*, 112(D11). <https://doi.org/10.1029/2006JD007507>
- Bach, H., Lampart, G., Ludwig, R., Mauser, W., Strasser, G., & Taschner, S. (2000). *Application of SAR data for flood modelling in Southern Germany*. 123.
- Bach, H., & Mauser, W. (2003). Methods and examples for remote sensing data assimilation in land surface process modeling. *IEEE Transactions on Geoscience and Remote Sensing*, 41(7), 1629-1637. <https://doi.org/10.1109/TGRS.2003.813270>
- Bach, H., Verhoef, W., & Schneider, K. (2001). Coupling remote sensing observation models and a growth model for improved retrieval of (geo) biophysical information from optical remote sensing data. *Remote Sensing for Agriculture, Ecosystems and Hydrology II*, 4171, 1-11.

- Baetens, L., Desjardins, C., & Hagolle, O. (2019). Validation of Copernicus Sentinel-2 Cloud Masks Obtained from MAJA, Sen2Cor, and FMask Processors Using Reference Cloud Masks Generated with a Supervised Active Learning Procedure. *Remote Sensing*, 11(4), 433. <https://doi.org/10.3390/rs11040433>
- Bargiel, D., & Herrmann, S. (2011). Multi-Temporal Land-Cover Classification of Agricultural Areas in Two European Regions with High Resolution Spotlight TerraSAR-X Data. *Remote Sensing*, 3(5), 859-877. <https://doi.org/10.3390/rs3050859>
- Bartalis, Z., Wagner, W., Naeimi, V., Hasenauer, S., Scipal, K., Bonekamp, H., Figa, J., & Anderson, C. (2007). Initial soil moisture retrievals from the METOP-A Advanced Scatterometer (ASCAT). *Geophysical Research Letters*, 34(20). <https://doi.org/10.1029/2007GL031088>
- Battude, M. (2017). *Estimation des rendements, des besoins et consommations en eau du maïs dans le Sud-Ouest de la France : Apport de la télédétection à hautes résolutions spatiale et temporelle*. Université Toulouse 3 Paul Sabatier.
- Battude, M., Al Bitar, A., Morin, D., Cros, J., Huc, M., Marais Sicre, C., Le Dantec, V., & Demarez, V. (2016). Estimating maize biomass and yield over large areas using high spatial and temporal resolution Sentinel-2 like remote sensing data. *Remote Sensing of Environment*, 184, 668-681. <https://doi.org/10.1016/j.rse.2016.07.030>
- Baup, F., Fieuzal, R., Marais-Sicre, C., Dejoux, J.-F., le Dantec, V., Mordelet, P., Claverie, M., Hagolle, O., Lopes, A., Keravec, P., Ceschia, E., Mialon, A., & Kidd, R. (2012). MCM'10 : An experiment for satellite multi-sensors crop monitoring from high to low resolution observations. 2012 *IEEE International Geoscience and Remote Sensing Symposium*, 4849-4852. <https://doi.org/10.1109/IGARSS.2012.6352527>
- Baup, Frédéric, Fieuzal, R., & Betbeder, J. (2015). Estimation of soybean yield from assimilated optical and radar data into a simplified agrometeorological model. *Geoscience and Remote Sensing Symposium (IGARSS), 2015 IEEE International*, 3961–3964. <http://ieeexplore.ieee.org/abstract/document/7326692/>
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., & Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3-4), 239-258. <https://doi.org/10.1016/j.isprsjprs.2003.10.002>
- Bergen, K. M., Goetz, S. J., Dubayah, R. O., Henebry, G. M., Hunsaker, C. T., Imhoff, M. L., Nelson, R. F., Parker, G. G., & Radeloff, V. C. (2009). Remote sensing of vegetation 3-D structure for biodiversity and habitat : Review and implications for lidar and radar spaceborne missions: VEGETATION 3-D STRUCTURE FOR BIODIVERSITY. *Journal of Geophysical Research: Biogeosciences*, 114(G2), n/a-n/a. <https://doi.org/10.1029/2008JG000883>
- Betbeder, J., Fieuzal, R., & Baup, F. (2016). Assimilation of LAI and Dry Biomass Data From Optical and SAR Images Into an Agro-Meteorological Model to Estimate Soybean Yield. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(6), 2540-2553. <https://doi.org/10.1109/JSTARS.2016.2541169>
- Béziat, P., Ceschia, E., & Dedieu, G. (2009). Carbon balance of a three crop succession over two cropland sites in South West France. *Agricultural and Forest Meteorology*, 149(10), 1628-1645. <https://doi.org/10.1016/j.agrformet.2009.05.004>

- Biaou, A. C. (2004). *De la méso-échelle à la micro-échelle : Désagrégation Spatio-temporelle Multifractale des Précipitations*. Ecole des Mines de Paris.
- Bicego, M., Dalfini, S., Vernazza, G., & Murino, V. (2003). Automatic road extraction from aerial images by probabilistic contour tracking. *Proceedings 2003 International Conference on Image Processing (Cat. No.03CH37429)*, 2, III-585-588. <https://doi.org/10.1109/ICIP.2003.1247312>
- Bindlish, R., & Barros, A. P. (2002). Subpixel variability of remotely sensed soil moisture : An inter-comparison study of SAR and ESTAR. *IEEE Transactions on Geoscience and Remote Sensing*, 40(2), 326-337. <https://doi.org/10.1109/36.992792>
- Biswas, A., Zeleke, T. B., & Si, B. C. (2012). Multifractal detrended fluctuation analysis in examining scaling properties of the spatial patterns of soil water storage. *Nonlinear Processes in Geophysics*, 19(2), 227-238. <https://doi.org/10.5194/npg-19-227-2012>
- Blake, A., Kohli, P., & Rother, C. (2011). *Markov random fields for vision and image processing*. Mit Press.
- Born, M., & Wolf, E. (1970). *Principles of Optics*. Pergamon Press.
- Bréon, F.-M., & Colzy, S. (1999). Cloud Detection from the Spaceborne POLDER Instrument and Validation against Surface Synoptic Observations. *Journal of Applied Meteorology*, 38, 777-785.
- Brocca, L., Morbidelli, R., Melone, F., & Moramarco, T. (2007). Soil moisture spatial variability in experimental areas of central Italy. *Journal of Hydrology*, 333(2-4), 356-373. <https://doi.org/10.1016/j.jhydrol.2006.09.004>
- Brocca, L., Tullo, T., Melone, F., Moramarco, T., & Morbidelli, R. (2012). Catchment scale soil moisture spatial-temporal variability. *Journal of Hydrology*, 422-423, 63-75. <https://doi.org/10.1016/j.jhydrol.2011.12.039>
- Budyko, M. I. (1961). The heat balance of the earth's surface. *Soviet Geography*, 2(4), 3-13.
- Burel, E. (2018). *Modélisation des hétérogénéités de la réserve utile et du développement des cultures au sein d'un sous-bassin versant en Midi-Pyrénées*. Université Toulouse 3 Paul Sabatier.
- Burke, E. J., Gurney, R. J., Simmonds, L. P., & O'Neill, P. E. (1998). Using a modeling approach to predict soil hydraulic properties from passive microwave measurements. *IEEE Transactions on Geoscience and Remote Sensing*, 36(2), 454-462. <https://doi.org/10.1109/36.662729>
- Burrough, P. A. (2000). High-resolution landform classification using fuzzy k-means. *Fuzzy Sets and Systems*, 16.
- Busch, F. A., Niemann, J. D., & Coleman, M. (2012). Evaluation of an empirical orthogonal function-based method to downscale soil moisture patterns based on topographical attributes : DOWNSCALING SOIL MOISTURE PATTERNS BASED ON TOPOGRAPHICAL ATTRIBUTES. *Hydrological Processes*, 26(18), 2696-2709. <https://doi.org/10.1002/hyp.8363>
- Carlson, T. (2007). An Overview of the « Triangle Method » for Estimating Surface Evapotranspiration and Soil Moisture from Satellite Imagery. *Sensors*, 7(8), 1612-1629. <https://doi.org/10.3390/s7081612>

- Carlson, T. N., Gillies, R. R., & Perry, E. M. (1994). A method to make use of thermal infrared temperature and NDVI measurements to infer surface soil water content and fractional vegetation cover. *Remote Sensing Reviews*, 9(1-2), 161-173.  
<https://doi.org/10.1080/02757259409532220>
- Carnahan, W. H., & Zhou, G. (1986). *Fourier transform techniques for the evaluation of the Thematic Mapper line spread function*.
- Castillo-Santiago, M. A., Ricker, M., & de Jong, B. H. J. (2010). Estimation of tropical forest structure from SPOT-5 satellite images. *International Journal of Remote Sensing*, 31(10), 2767-2782.  
<https://doi.org/10.1080/01431160903095460>
- Cayan, D. R., & Georgakakos, K. P. (1995). Hydroclimatology of Continental Watersheds : 2. Spatial Analyses. *Water Resources Research*, 31(3), 677-697. <https://doi.org/10.1029/94WR02376>
- Chambers, J. M., Mallows, C. L., & Stuck, B. W. (1976). A method for simulating stable random variables. *Journal of the american statistical association*, 71(354), 340-344.
- Chauhan, N. S., Miller, S., & Ardanuy, P. (2003). Spaceborne soil moisture estimation at high resolution : A microwave-optical/IR synergistic approach. *International Journal of Remote Sensing*, 24(22), 4599-4622. <https://doi.org/10.1080/0143116031000156837>
- Cheng, Q. (2000). Multifractal theory and geochemical element distribution pattern. *地球科学*, 3.
- Cheng, Q., Russell, H., Sharpe, D., Kenny, F., & Qin, P. (2001). GIS-based statistical and fractal/multifractal analysis of surface stream patterns in the Oak Ridges Moraine. *Computers & Geosciences*, 27(5), 513-526. [https://doi.org/10.1016/S0098-3004\(00\)00112-6](https://doi.org/10.1016/S0098-3004(00)00112-6)
- Chica-Olmo, M., & Abarca-Hernandez, F. (2000). Computing geostatistical image texture for remotely sensed data classification. *Computers & Geosciences*, 26(4), 373-383.
- Choi, M., & Hur, Y. (2012). A microwave-optical/infrared disaggregation for improving spatial representation of soil moisture using AMSR-E and MODIS products. *Remote Sensing of Environment*, 124, 259-269. <https://doi.org/10.1016/j.rse.2012.05.009>
- Choi, T. (2002). *KONOS satellite on orbit modulation transfer function (MTF) measurement using edge and pulse method* [Electrical Engineering Department]. South Dakota State University.
- Cimpoi, M., Maji, S., & Vedaldi, A. (2015). Deep filter banks for texture recognition and segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3828-3836.  
<https://doi.org/10.1109/CVPR.2015.7299007>
- Claverie, M., Demarez, V., Duchemin, B., Hagolle, O., Ducrot, D., Marais-Sicre, C., Dejoux, J.-F., Huc, M., Keravec, P., Béziat, P., Fieuzal, R., Ceschia, E., & Dedieu, G. (2012). Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data. *Remote Sensing of Environment*, 124, 844-857.  
<https://doi.org/10.1016/j.rse.2012.04.005>
- Comaniciu, D., & Meer, P. (2002). Mean shift : A robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5), 603-619.  
<https://doi.org/10.1109/34.1000236>

- Costa, A. F., Humpire-Mamani, G., & Traina, A. J. M. (2012). An Efficient Algorithm for Fractal Analysis of Textures. *2012 25th SIBGRAPI Conference on Graphics, Patterns and Images*, 39-46. <https://doi.org/10.1109/SIBGRAPI.2012.15>
- Costa, M., Goldberger, A. L., & Peng, C.-K. (2002). Multiscale Entropy Analysis of Complex Physiologic Time Series. *Physical Review Letters*, 89(6). <https://doi.org/10.1103/PhysRevLett.89.068102>
- Courault, D., Bsaibes, A., Kpemlie, E., Hadria, R., Hagolle, O., Marloie, O., Hanocq, J.-F., Olioso, A., Bertrand, N., & Desfonds, V. (2008). Assessing the Potentialities of FORMOSAT-2 Data for Water and Crop Monitoring at Small Regional Scale in South-Eastern France. *Sensors*, 8(5), 3460-3481. <https://doi.org/10.3390/s8053460>
- Cracknell, A. P. (1998). Review article Synergy in remote sensing-what's in a pixel? *International Journal of Remote Sensing*, 19(11), 2025-2047. <https://doi.org/10.1080/014311698214848>
- Crow, W. T., Berg, A. A., Cosh, M. H., Loew, A., Mohanty, B. P., Panciera, R., de Rosnay, P., Ryu, D., & Walker, J. P. (2012). Upscaling sparse ground-based soil moisture observations for the validation of coarse-resolution satellite soil moisture products : UPSCALING SOIL MOISTURE. *Reviews of Geophysics*, 50(2). <https://doi.org/10.1029/2011RG000372>
- Dai, A., Trenberth, K. E., & Qian, T. (2004). A Global Dataset of Palmer Drought Severity Index for 1870–2002 : Relationship with Soil Moisture and Effects of Surface Warming. *Journal of Hydrometeorology*, 5(6), 1117-1130. <https://doi.org/10.1175/JHM-386.1>
- Das, N. N., & Mohanty, B. P. (2006). Root zone soil moisture assessment using remote sensing and vadose zone modeling. *Vadose Zone Journal*, 5(1), 296-307.
- Das, Narendra N., Entekhabi, D., & Njoku, E. G. (2011). An Algorithm for Merging SMAP Radiometer and Radar Data for High-Resolution Soil-Moisture Retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 49(5), 1504-1512. <https://doi.org/10.1109/TGRS.2010.2089526>
- Daubechies, I. (1990). The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, 36(5), 961-1005. <https://doi.org/10.1109/18.57199>
- De Cola, L. (1989). Fractal Analysis of a Classified Landscape Scene. *Photogrammetric Engineering and Remote Sensing*, 55(5), 601-610.
- De Fries, R. S., Hansen, M., Townshend, J. R. G., & Sohlberg, R. (1998). Global land cover classifications at 8 km spatial resolution : The use of training data derived from Landsat imagery in decision tree classifiers. *International Journal of Remote Sensing*, 19(16), 3141-3168. <https://doi.org/10.1080/014311698214235>
- de Montera, L., Barthès, L., Mallet, C., & Golé, P. (2009). Rain universal multifractal parameters revisited with dual-beam spectropluviometer measurements. *Journal of Hydrometeorology*, 493-506.
- Dean, A. M., & Smith, G. M. (2003). An evaluation of per-parcel land cover mapping using maximum likelihood class probabilities. *International Journal of Remote Sensing*, 24(14), 2905-2920. <https://doi.org/10.1080/01431160210155910>
- Dedieu, G., Karnieli, A., Hagolle, O., Jeanjean, H., Cabot, F., & Ferrier, P. (2007). The VENUS mission : Earth observation with high spatial and temporal resolution capabilities. *Geophysical Research Abstracts*, 9, 06947.

- Deidda, R. (2000). Rainfall downscaling in a space-time multifractal framework. *Water Resources Research*, 36(7), 1779-1794. <https://doi.org/10.1029/2000WR900038>
- Dejoux, J.-F., Dedieu, G., Hagolle, O., Ducrot, D., Menaut, J.-C., Ceschia, E., Baup, F., Demarez, V., Marais-Sicre, C., Kadiri, M., & Gascoin, S. (2012). *Kalideos OSR MiPy : Un observatoire pour la recherche et la démonstration des applications de la télédétection à la gestion des territoires*. 16.
- Delenne, C., Rabatel, G., Agurto, V., & Deshayes, M. (2006). *VINE PLOT DETECTION IN AERIAL IMAGES USING FOURIER ANALYSIS*. 6.
- Demarez, V. (2013). *Télédétection des surfaces continentales*.
- D'Errico, J. (2017). *Shape Language Modelling*.  
<https://fr.mathworks.com/matlabcentral/fileexchange/24443-slm-shape-language-modeling>
- Didan, K., Munoz, A. B., Solano, R., & Huete, A. (2015). MODIS Vegetation Index User's Guide (MOD13 Series). *Vegetation Index and Phenology Lab, The University of Arizona*, 1-38.
- Djamai, N., Magagi, R., Goïta, K., Merlin, O., Kerr, Y., & Roy, A. (2016). A combination of DISPATCH downscaling algorithm with CLASS land surface scheme for soil moisture estimation at fine scale during cloudy days. *Remote Sensing of Environment*, 184, 1-14.  
<https://doi.org/10.1016/j.rse.2016.06.010>
- Dobriyal, P., Qureshi, A., Badola, R., & Hussain, S. A. (2012). A review of the methods available for estimating soil moisture and its implications for water resource management. *Journal of Hydrology*, 458-459, 110-117. <https://doi.org/10.1016/j.jhydrol.2012.06.021>
- Dozier, J. (1989). Spectral signature of alpine snow cover from the landsat thematic mapper. *Remote Sensing of Environment*, 28, 9-22. [https://doi.org/10.1016/0034-4257\(89\)90101-6](https://doi.org/10.1016/0034-4257(89)90101-6)
- Dubayah, R. O., & Drake, J. B. (2000). Lidar for remote sensing for forestry. *Journal of Forestry*, 98(6), 44-46.
- Dubovik, O., Holben, B., Eck, T. F., Smirnov, A., Kaufman, Y. J., King, M. D., Tanre, D., & Slutsker, I. (2002). Variability of Absorption and Optical Properties of Key Aerosol Types Observed in Worldwide Locations. *JOURNAL OF THE ATMOSPHERIC SCIENCES*, 59, 19.
- Dubrulle, B. (1994). Intermittency in fully developed turbulence : Log-Poisson statistics and generalized scale covariance. *Physical review letters*, 73(7), 959.  
<https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.73.959>
- Ekercin, S. (2007). Water Quality Retrievals from High Resolution Ikonos Multispectral Imagery : A Case Study in Istanbul, Turkey. *Water, Air, and Soil Pollution*, 183(1-4), 239-251.  
<https://doi.org/10.1007/s11270-007-9373-5>
- El Hajj, M., Baghdadi, N., Zribi, M., Rodríguez-Fernández, N., Wigneron, J., Al-Yaari, A., Al Bitar, A., Albergel, C., & Calvet, J.-C. (2018). Evaluation of SMOS, SMAP, ASCAT and Sentinel-1 Soil Moisture Products at Sites in Southwestern France. *Remote Sensing*, 10(4), 569.  
<https://doi.org/10.3390/rs10040569>
- Engman, E. T. (1991). Applications of microwave remote sensing of soil moisture for water resources and agriculture. *Remote Sensing of Environment*, 35(2-3), 213-226.  
[https://doi.org/10.1016/0034-4257\(91\)90013-V](https://doi.org/10.1016/0034-4257(91)90013-V)



- Entekhabi, D., Njoku, E. G., O'Neill, P. E., Kellogg, K. H., Crow, W. T., & Edelstein, W. N. (2010). The soil moisture active passive (SMAP) mission. *Proceedings of the IEEE*, 98(5), 704-716.
- Entekhabi, Dara, Reichle, R. H., Koster, R. D., & Crow, W. T. (2010). Performance Metrics for Soil Moisture Retrievals and Application Requirements. *Journal of Hydrometeorology*, 11(3), 832-840. <https://doi.org/10.1175/2010JHM1223.1>
- Entin, J. K., Robock, A., Vinnikov, K. Y., Hollinger, S. E., Liu, S., & Namkhai, A. (2000). Temporal and spatial scales of observed soil moisture variations in the extratropics. *Journal of Geophysical Research: Atmospheres*, 105(D9), 11865-11877. <https://doi.org/10.1029/2000JD900051>
- Fabre, S., Briottet, X., & Lesaignoux, A. (2015). Estimation of Soil Moisture Content from the Spectral Reflectance of Bare Soils in the 0.4–2.5  $\mu\text{m}$  Domain. *Sensors*, 15(2), 3262-3281. <https://doi.org/10.3390/s150203262>
- Falconer, K. (2004). *Fractal geometry : Mathematical foundations and applications* (John Wiley & Sons).
- Famiglietti, J. S., Rudnicki, J. W., & Rodell, M. (1998). Variability in surface moisture content along a hillslope transect : Rattlesnake Hill, Texas. *Journal of Hydrology*, 210(1-4), 259-281. [https://doi.org/10.1016/S0022-1694\(98\)00187-5](https://doi.org/10.1016/S0022-1694(98)00187-5)
- Famiglietti, J. S., Ryu, D., Berg, A. A., Rodell, M., & Jackson, T. J. (2008). Field observations of soil moisture variability across scales : SOIL MOISTURE VARIABILITY ACROSS SCALES. *Water Resources Research*, 44(1). <https://doi.org/10.1029/2006WR005804>
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., & Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2), RG2004. <https://doi.org/10.1029/2005RG000183>
- Fieuzal, R., Marais Sicre, C., & Baup, F. (2017). Estimation of corn yield using multi-temporal optical and radar satellite data and artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation*, 57, 14-23. <https://doi.org/10.1016/j.jag.2016.12.011>
- Fieuzal, Rémy, & Baup, F. (2015). Estimation of sunflower yield using multi-spectral satellite data (optical or radar) in a simplified agro-meteorological model. *Geoscience and Remote Sensing Symposium (IGARSS), 2015 IEEE International*, 4001–4004. <http://ieeexplore.ieee.org/abstract/document/7326702/>
- Fieuzal, Rémy, Baup, F., & Marais-Sicre, C. (2013). Monitoring Wheat and Rapeseed by Using Synchronous Optical and Radar Satellite Data—From Temporal Signatures to Crop Parameters Estimation. *Advances in Remote Sensing*, 02(02), 162-180. <https://doi.org/10.4236/ars.2013.22020>
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Fraser, R., & Kaufman, Y. (1985). The Relative Importance of Aerosol Scattering and Absorption in Remote Sensing. *IEEE Transactions on Geoscience and Remote Sensing*, GE-23(5), 625-633. <https://doi.org/10.1109/TGRS.1985.289380>



- Frisch, U., Sulem, P.-L., & Nelkin, M. (1978). A simple dynamical model of intermittent fully developed turbulence. *Journal of Fluid Mechanics*, 87(04), 719.  
<https://doi.org/10.1017/S0022112078001846>
- Gagnon, J.-S., Lovejoy, S., & Schertzer, D. (2006). Multifractal earth topography. *Nonlinear Processes in Geophysics*, 13(5), 541–570.
- Gao, B.-C., & Kaufman, Y. J. (1995). Selection of the 1.375- $\mu$ m MODIS channel for remote sensing of cirrus clouds and stratospheric aerosols from space. *Journal of the Atmospheric Sciences*, 52(23), 4231-4237.
- Gascon, F., Bouzinac, C., Thépaut, O., Jung, M., Francesconi, B., Louis, J., Lonjou, V., Lafrance, B., Massera, S., Gaudel-Vacaresse, A., Languille, F., Alhammoud, B., Viallefont, F., Pflug, B., Bieniarz, J., Clerc, S., Pessiot, L., Trémas, T., Cadau, E., ... Fernandez, V. (2017). Copernicus Sentinel-2A Calibration and Products Validation Status. *Remote Sensing*, 9(6), 584.  
<https://doi.org/10.3390/rs9060584>
- Gatti, A., & Naud, C. (2017). *Sentinel-2 Products Specification Document*. 487.
- Gires, A., Onof, C., Maksimovic, C., Schertzer, D., Tchiguirinskaia, I., & Simoes, N. (2012). Quantifying the impact of small scale unmeasured rainfall variability on urban runoff through multifractal downscaling : A case study. *Journal of Hydrology*, 442-443, 117-128.  
<https://doi.org/10.1016/j.jhydrol.2012.04.005>
- Gires, A., Tchiguirinskaia, I., Schertzer, D., & Lovejoy, S. (2011). Analyses multifractales et spatio-temporelles des précipitations du modèle Mésos-NH et des données radar. *Hydrological Sciences Journal*, 56(3), 380-396. <https://doi.org/10.1080/02626667.2011.564174>
- Goodwin, N. R., Collett, L. J., Denham, R. J., Flood, N., & Tindall, D. (2013). Cloud and cloud shadow screening across Queensland, Australia : An automated method for Landsat TM/ETM+ time series. *Remote Sensing of Environment*, 134, 50-65.  
<https://doi.org/10.1016/j.rse.2013.02.019>
- Gupta, V. K., & Waymire, E. C. (1997). Reply-Universal Multifractals Do Exist! : Comments on A Statistical Analysis of Mesoscale Rainfall as a Random Cascade. *Journal of Applied Meteorology*, 36(9), 1304-1307.
- Gustafson, E. J. (1998). Quantifying Landscape Spatial Pattern : What Is the State of the Art? *Ecosystems*, 1(2), 143-156.
- Gutman, G., Byrnes, R., Masek, J., Covington, S., Justice, C., Franks, S., & Headley, R. (2008). Towards monitoring Land-cover and land-use changes at a global scale : The global land survey. *Photogrammetric Engineering & Remote Sensing*, 74, 6-10.
- Hagolle, O., Dedieu, G., Mougenot, B., Debaecker, V., Duchemin, B., & Meygret, A. (2008). Correction of aerosol effects on multi-temporal images acquired with constant viewing angles : Application to Formosat-2 images. *Remote Sensing of Environment*, 112(4), 1689-1701.  
<https://doi.org/10.1016/j.rse.2007.08.016>
- Hagolle, O., Huc, M., Pascual, D. V., & Dedieu, G. (2010). A multi-temporal method for cloud detection, applied to FORMOSAT-2, VEN $\mu$ S, LANDSAT and SENTINEL-2 images. *Remote Sensing of Environment*, 114(8), 1747-1755. <https://doi.org/10.1016/j.rse.2010.03.002>

- Hagolle, Olivier, Huc, M., Descardins, C., Auer, S., & Richter, R. (2017). *MAJA Algorithm Theoretical Basis Document*. <https://doi.org/10.5281/zenodo.1209633>
- Hagolle, Olivier, Huc, M., Villa Pascual, D., & Dedieu, G. (2015). A Multi-Temporal and Multi-Spectral Method to Estimate Aerosol Optical Thickness over Land, for the Atmospheric Correction of FormoSat-2, LandSat, VENμS and Sentinel-2 Images. *Remote Sensing*, 7(3), 2668-2691. <https://doi.org/10.3390/rs70302668>
- Hagolle, Olivier, Sylvander, S., Huc, M., Claverie, M., Clesse, D., Dechoz, C., Lonjou, V., & Poulain, V. (2015). SPOT-4 (Take 5) : Simulation of Sentinel-2 Time Series on 45 Large Sites. *Remote Sensing*, 7(9), 12242-12264. <https://doi.org/10.3390/rs70912242>
- Hall, F. G., Strebel, D. E., Nickeson, J. E., & Goetz, S. J. (1991). Radiometric rectification : Toward a common radiometric response among multirate, multisensor images. *Remote Sensing of Environment*, 35(1), 11-27. [https://doi.org/10.1016/0034-4257\(91\)90062-B](https://doi.org/10.1016/0034-4257(91)90062-B)
- Halsey, T. C., Jensen, M. H., Kadanoff, L. P., Procaccia, I., & Shraiman, B. I. (1986). Fractal measures and their singularities : The characterization of strange sets. *Physical Review A*, 33(2), 1141–1151.
- Hansen, M. C., & Loveland, T. R. (2012). A review of large area monitoring of land cover change using Landsat data. *Remote Sensing of Environment*, 122, 66-74. <https://doi.org/10.1016/j.rse.2011.08.024>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610-621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Haralick, R. M., Sternberg, S. R., & Zhuang, X. (1987). Image Analysis Using Mathematical Morphology. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-9(4), 532-550. <https://doi.org/10.1109/TPAMI.1987.4767941>
- Haubrock, S. -N., Chabrillat, S., Lemmertz, C., & Kaufmann, H. (2008). Surface soil moisture quantification models from reflectance data under field conditions. *International Journal of Remote Sensing*, 29(1), 3-29. <https://doi.org/10.1080/01431160701294695>
- Hawley, M. E., Jackson, T. J., & McCuen, R. H. (1983). Surface soil moisture variation on small agricultural watersheds. *Journal of Hydrology*, 62(1-4), 179-200. [https://doi.org/10.1016/0022-1694\(83\)90102-6](https://doi.org/10.1016/0022-1694(83)90102-6)
- Holzer, N., Vijay, S., Yao, T., Xu, B., Buchroithner, M., & Bolch, T. (2015). Four decades of glacier variations at Muztagh Ata (eastern Pamir) : A multi-sensor study including Hexagon KH-9 and Pléiades data. *The Cryosphere*, 9(6), 2071-2088. <https://doi.org/10.5194/tc-9-2071-2015>
- Hu, M.-G., Wang, J.-F., & Ge, Y. (2009). Super-Resolution Reconstruction of Remote Sensing Images Using Multifractal Analysis. *Sensors*, 9(11), 8669-8683. <https://doi.org/10.3390/s91108669>
- Hu, Z., Islam, S., & Cheng, Y. (1997). Statistical characterization of remotely sensed soil moisture images. *Remote Sensing of Environment*, 61(2), 310-318. [https://doi.org/10.1016/S0034-4257\(97\)89498-9](https://doi.org/10.1016/S0034-4257(97)89498-9)
- Huang, C., Goward, S. N., Masek, J. G., Thomas, N., Zhu, Z., & Vogelmann, J. E. (2010). An automated approach for reconstructing recent forest disturbance history using dense Landsat time series

- stacks. *Remote Sensing of Environment*, 114(1), 183-198.  
<https://doi.org/10.1016/j.rse.2009.08.017>
- Hubert, P., Tchiguirinskaia, I., Schertzer, D., Bendjoudi, H., & Lovejoy, S. (2007). Predetermination of floods. *Extreme Hydrological Events: New Concepts for Security*, 78, 185-198.
- Hubert, P., Tessier, Y., Lovejoy, S., Schertzer, D., Schmitt, F., Ladoy, P., Carbonnel, J. P., Violette, S., & Desurosne, I. (1993). Multifractals and Extreme Rainfall Events. *Geophysical Research Letters*, 20(10), 931-934. <https://doi.org/10.1029/93GL01245>
- Hughes, M., & Hayes, D. (2014). Automated Detection of Cloud and Cloud Shadow in Single-Date Landsat Imagery Using Neural Networks and Spatial Post-Processing. *Remote Sensing*, 6(6), 4907-4926. <https://doi.org/10.3390/rs6064907>
- Humeau-Heurtier, A. (2019). Texture Feature Extraction Methods : A Survey. *IEEE Access*, 7, 8975-9000. <https://doi.org/10.1109/ACCESS.2018.2890743>
- Ines, A. V. M., Mohanty, B. P., & Shin, Y. (2013). An unmixing algorithm for remotely sensed soil moisture : AN UNMIXING ALGORITHM FOR REMOTELY SENSED SOIL MOISTURE. *Water Resources Research*, 49(1), 408-425. <https://doi.org/10.1029/2012WR012379>
- Inglada, J. (2015, février). *Cartographie Thématique – M2-SIA*.
- Irons, J. R., Dwyer, J. L., & Barsi, J. A. (2012). The next Landsat satellite : The Landsat Data Continuity Mission. *Remote Sensing of Environment*, 122, 11-21.  
<https://doi.org/10.1016/j.rse.2011.08.026>
- Jackson, T. J., Le Vine, D. M., Hsu, A. Y., Oldak, A., Starks, P. J., Swift, C. T., Isham, J. D., & Haken, M. (1999). Soil moisture mapping at regional scales using microwave radiometry : The Southern Great Plains Hydrology Experiment. *IEEE Transactions on Geoscience and Remote Sensing*, 37(5), 2136-2151. <https://doi.org/10.1109/36.789610>
- Jackson, T. J., & Schmugge, T. J. (1991). Vegetation effects on the microwave emission of soils. *Remote Sensing of Environment*, 36(3), 203-212. [https://doi.org/10.1016/0034-4257\(91\)90057-D](https://doi.org/10.1016/0034-4257(91)90057-D)
- Jana, R. B. (2010). *Scaling characteristics of soil hydraulic parameters at varying spatial resolutions*. Texas A&M University.
- Kaheil, Y. H., Gill, M. K., McKee, M., Bastidas, L. A., & Rosero, E. (2008). Downscaling and Assimilation of Surface Soil Moisture Using Ground Truth Measurements. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5), 1375-1384. <https://doi.org/10.1109/TGRS.2008.916086>
- Kass, M., Witkin, A., & Terzopoulos, D. (1988). Snakes : Active contour models. *International Journal of Computer Vision*, 1(4), 321-331. <https://doi.org/10.1007/BF00133570>
- Katul, G. G., Porporato, A., Daly, E., Oishi, A. C., Kim, H.-S., Stoy, P. C., Juang, J.-Y., & Siqueira, M. B. (2007). On the spectrum of soil moisture from hourly to interannual scales : SPECTRUM OF SOIL MOISTURE CONTENT. *Water Resources Research*, 43(5).  
<https://doi.org/10.1029/2006WR005356>
- Kaufman, Y. J., & Sendra, C. (1988). Algorithm for automatic atmospheric corrections to visible and near-IR satellite imagery. *International Journal of Remote Sensing*, 9(8), 1357-1381.  
<https://doi.org/10.1080/01431168808954942>

- Kavzoglu, T., & Mather, P. M. (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24(23), 4907-4938.  
<https://doi.org/10.1080/0143116031000114851>
- Keller, J. M., Chen, S., & Crownover, R. M. (1989). Texture description and segmentation through fractal geometry. *Computer Vision, Graphics, and image processing*, 45(2), 150-166.
- Kergomard, C. (1990). La télédétection aérospatiale : Une introduction. In *Cours de télédétection*.
- Kerr, Y. H., Waldteufel, P., Richaume, P., Wigneron, J. P., Ferrazzoli, P., Mahmoodi, A., Al Bitar, A., Cabot, F., Gruhier, C., Juglea, S. E., Leroux, D., Mialon, A., & Delwart, S. (2012). The SMOS Soil Moisture Retrieval Algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1384-1403. <https://doi.org/10.1109/TGRS.2012.2184548>
- Kerr, Y. H., Waldteufel, P., Wigneron, J.-P., Delwart, S., Cabot, F., Boutin, J., Escorihuela, M.-J., Font, J., Reul, N., Gruhier, C., Juglea, S. E., Drinkwater, M. R., Hahne, A., Martín-Neira, M., & Susanne Mecklenburg. (2010). The SMOS Mission : New Tool for Monitoring Key Elements of the Global Water Cycle. *Proceedings of the IEEE*, 98(5), 666-687.  
<https://doi.org/10.1109/JPROC.2010.2043032>
- Kerr, Y., Jacquette, E., Al Bitar, A., Cabot, F., Mialon, A., Richaume, P., & Wigneron, J.-P. (2013). CATDS SMOS L3 soil moisture retrieval processor : Algorithm theoretical baseline document (ATBD). *CESBIO, Toulouse, France*.
- Kim, G., & Barros, A. P. (2002a). Downscaling of remotely sensed soil moisture with a modified fractal interpolation method using contraction mapping and ancillary data. *Remote Sensing of Environment*, 83(3), 400-413.  
<http://www.sciencedirect.com/science/article/pii/S0034425702000445>
- Kim, G., & Barros, A. P. (2002b). Space-time characterization of soil moisture from passive microwave remotely sensed imagery and ancillary data. *Remote Sensing of Environment*, 81(2-3), 393-403. [https://doi.org/10.1016/S0034-4257\(02\)00014-7](https://doi.org/10.1016/S0034-4257(02)00014-7)
- Kim, H.-C., Pang, S., Je, H.-M., Kim, D., & Yang Bang, S. (2003). Constructing support vector machine ensemble. *Pattern Recognition*, 36(12), 2757-2767. [https://doi.org/10.1016/S0031-3203\(03\)00175-4](https://doi.org/10.1016/S0031-3203(03)00175-4)
- Kim, J., & Hogue, T. S. (2012). Improving Spatial Soil Moisture Representation Through Integration of AMSR-E and MODIS Products. *IEEE Transactions on Geoscience and Remote Sensing*, 50(2), 446-460. <https://doi.org/10.1109/TGRS.2011.2161318>
- King, M. D., Kaufman, Y. J., Tanré, D., & Nakajima, T. (1999). Remote Sensing of Tropospheric Aerosols from Space : Past, Present, and Future. *Bulletin of the American Meteorological society*, 80(11), 2229-2260.
- Kneizys, F. X., Shettle, E. P., Abreu, L. W., Chetwynd, J. H., & Anderson, G. P. (s. d.). User's guide to LOWTRAN-7. *Air Force Geophysics Lab Hanscom AFB MA, AFGL-TR-88-0177*, 1988.
- Ko, A., Mascaro, G., & Vivoni, E. R. (2016). Irrigation Impacts on Scaling Properties of Soil Moisture and the Calibration of a Multifractal Downscaling Model. *IEEE Transactions on Geoscience and Remote Sensing*, 54(6), 3128-3142. <https://doi.org/10.1109/TGRS.2015.2511628>
- Kolmogorov, A. N. (1940). Curves in Hilbert space which are invariant with respect to a one-parameter group of motions. *Dokl. Akad. Nauk SSSR*, 26(1), 6-9.

- Kolmogorov, A. N. (1962). A refinement of previous hypotheses concerning the local structure of turbulence in a viscous incompressible fluid at high Reynolds number. *Journal of Fluid Mechanics*, 13(01), 82. <https://doi.org/10.1017/S0022112062000518>
- Kolmogorov, A. N. (1941). The local structure of turbulence in incompressible viscous fluid for very large Reynolds numbers. *Dokl. Akad. Nauk SSSR*, 30, 299–303.
- Kontgis, C., Schneider, A., & Ozdogan, M. (2015). Mapping rice paddy extent and intensification in the Vietnamese Mekong River Delta with dense time stacks of Landsat data. *Remote Sensing of Environment*, 169, 255-269. <https://doi.org/10.1016/j.rse.2015.08.004>
- Kravchenko, A. N., Boast, C. W., & Bullock, D. G. (1999). Multifractal analysis of soil spatial variability. *Agronomy Journal*, 91(6), 1033-1041.
- Laferrière, A., & Gaonac'h, H. (1999). Multifractal properties of visible reflectance fields from basaltic volcanoes. *Journal of Geophysical Research: Solid Earth*, 104(B3), 5115-5126. <https://doi.org/10.1029/1998JB900023>
- Lafore, J. P., Stein, J., Asencio, N., Bougeault, P., Ducrocq, V., Duron, J., Fischer, C., Masson, V., Pinty, J. P., Redelsperger, J. L., & Richard, E. (1997). The Meso-NH Atmospheric Simulation System. Part I: adiabatic formulation and control simulations. *Annales Geophysicae*, 16(1), 90-109. <https://doi.org/10.1007/s00585-997-0090-6>
- Lafrance, B., Lenot, X., Ruffel, C., Cao, P., & Rabaute, T. (2012). Outils de prétraitements des images optiques Kalideos. *Revue Française de Photogrammétrie et de Télédétection*, 197, 10-16.
- Lam, N. S.-N. (1990). Description and Measurement of Landsat TM Images Using Fractals. *Photogrammetric Engineering and Remote Sensing*, 56, 187-195.
- Lampkin, D. J., & Yool, S. R. (2004). Monitoring mountain snowpack evolution using near-surface optical and thermal properties. *Hydrological Processes*, 18(18), 3527-3542. <https://doi.org/10.1002/hyp.5797>
- Landais, F., Schmidt, F., & Lovejoy, S. (2019). Topography of (exo)planets. *Monthly Notices of the Royal Astronomical Society*, 484(1), 787-793. <https://doi.org/10.1093/mnras/sty3253>
- Lavallée, D., Lovejoy, S., Schertzer, D., & Ladoy, P. (1993). Nonlinear variability of landscape topography : Multifractal analysis and simulation. In *Fractals in Geography* (Prentice Hall, p. 158-192). Nina Siu-Ngan Lam and Lee De Cola.
- Lawrence, S., Giles, C. L., Ah Chung Tsoi, & Back, A. D. (1997). Face recognition : A convolutional neural-network approach. *IEEE Transactions on Neural Networks*, 8(1), 98-113. <https://doi.org/10.1109/72.554195>
- Le Hégarat-Masclé, S., & André, C. (2009). Use of Markov Random Fields for automatic cloud/shadow detection on high resolution optical images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(4), 351-366. <https://doi.org/10.1016/j.isprsjprs.2008.12.007>
- Lee, D. S., Shan, J., & Bethel, J. S. (2003). Class-Guided Building Extraction from Ikonos Imagery. *Photogrammetric Engineering & Remote Sensing*, 69(2), 143-150. <https://doi.org/10.14358/PERS.69.2.143>
- Lenoble, J. (1985). Radiative transfer in scattering and absorbing atmospheres : Standard computational procedures. *A. Deepak Publishing*, 1(2).

- Lenoble, J., Herman, M., Deuzé, J. L., Lafrance, B., Santer, R., & Tanré, D. (2007). A successive order of scattering code for solving the vector equation of transfer in the earth's atmosphere with aerosols. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 107(3), 479-507. <https://doi.org/10.1016/j.igsrt.2007.03.010>
- Lévy, P. (1937). *Théorie de l'addition des variables aléatoires* (Gauthiers-Villars).
- Levy, R. C., Mattoo, S., Munchak, L. A., Remer, L. A., Sayer, A. M., Patadia, F., & Hsu, N. C. (2013). The Collection 6 MODIS aerosol products over land and ocean. *Atmospheric Measurement Techniques*, 6(11), 2989-3034. <https://doi.org/10.5194/amt-6-2989-2013>
- Lissens, G., Kempeneers, P., & Fierens, F. (2000). Development of a cloud, snow and cloud shadow mask for VEGETATION imagery. *Proceedings of VEGETATION 2000 Symposium*, 3, 303-306.
- Loew, A., & Mauser, W. (2008). On the Disaggregation of Passive Microwave Soil Moisture Data Using A Priori Knowledge of Temporally Persistent Soil Moisture Fields. *IEEE Transactions on Geoscience and Remote Sensing*, 46(3), 819-834. <https://doi.org/10.1109/TGRS.2007.914800>
- Louis, J., Debaecker, V., Pflug, B., Main-Knorn, M., Bieniarz, J., Mueller-Wilm, U., Cadau, E., & Gascon, F. (2016). SENTINEL-2 SEN2COR: L2A PROCESSOR FOR USERS. *Proceedings of the Living Planet Symposium, Prague, Czech Republic*, 9-13.
- Lovejoy, S. (1982). Area-Perimeter Relation for Rain and Cloud Areas. *Science*, 216(4542), 185-187. <https://doi.org/10.1126/science.216.4542.185>
- Lovejoy, S., & Mandelbrot, B. B. (1985). Fractal properties of rain, and a fractal model. *Tellus A*, 37A(3), 209-232. <https://doi.org/10.1111/j.1600-0870.1985.tb00423.x>
- Lovejoy, S., & Schertzer, D. (2006). Multifractals, cloud radiances and rain. *Journal of Hydrology*, 322(1-4), 59-88. <https://doi.org/10.1016/j.jhydrol.2005.02.042>
- Lovejoy, S., & Schertzer, D. (2008). Turbulence, raindrops and the  $l^{1/2}$  number density law. *New Journal of Physics*, 10(7), 075017. <https://doi.org/10.1088/1367-2630/10/7/075017>
- Lovejoy, S., & Schertzer, D. (2010a). Towards a new synthesis for atmospheric dynamics : Space-time cascades. *Atmospheric Research*, 96(1), 1-52. <https://doi.org/10.1016/j.atmosres.2010.01.004>
- Lovejoy, S., & Schertzer, D. (2010b). On the simulation of continuous in scale universal multifractals, part I : Spatially continuous processes. *Computers & Geosciences*, 36(11), 1393-1403. <https://doi.org/10.1016/j.cageo.2010.04.010>
- Lovejoy, S., & Schertzer, D. (2010c). On the simulation of continuous in scale universal multifractals, Part II : Space-time processes and finite size corrections. *Computers & Geosciences*, 36(11), 1404-1413. <https://doi.org/10.1016/j.cageo.2010.07.001>
- Lovejoy, S., & Schertzer, D. (2012a). Low-Frequency Weather and the Emergence of the Climate. In A. S. Sharma, A. Bunde, V. P. Dimri, & D. N. Baker (Éd.), *Geophysical Monograph Series* (Vol. 196, p. 231-254). American Geophysical Union. <https://doi.org/10.1029/2011GM001087>
- Lovejoy, S., & Schertzer, D. (2012b). Haar wavelets, fluctuations and structure functions : Convenient choices for geophysics. *Nonlinear Processes in Geophysics*, 19(5), 513-527. <https://doi.org/10.5194/npg-19-513-2012>



- Lovejoy, S., Schertzer, D., Lilley, M., Strawbridge, K. B., & Radkevich, A. (2008a). Scaling turbulent atmospheric stratification. I : Turbulence and waves. *Quarterly Journal of the Royal Meteorological Society*, 134(631), 277-300. <https://doi.org/10.1002/qj.201>
- Lovejoy, S., Schertzer, D., & Stanway, J. D. (2001). Direct Evidence of Multifractal Atmospheric Cascades from Planetary Scales down to 1 km. *Physical Review Letters*, 86(22), 5200-5203. <https://doi.org/10.1103/PhysRevLett.86.5200>
- Lovejoy, S., Tarquis, A. M., Gaonac'h, H., & Schertzer, D. (2008b). Single-and multiscale remote sensing techniques, multifractals, and MODIS-derived vegetation and soil moisture. *Vadose Zone Journal*, 7(2), 533–546. <https://dl.sciencesocieties.org/publications/vzi/abstracts/7/2/533>
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. <https://doi.org/10.1080/01431160600746456>
- Lucieer, A., & van der Werff, H. (2007). Panchromatic wavelet texture features fused with multispectral bands for improved classification of high-resolution satellite imagery. *2007 IEEE International Geoscience and Remote Sensing Symposium*, 5154-5157. <https://doi.org/10.1109/IGARSS.2007.4424022>
- Lyapustin, A., Wang, Y., & Frey, R. (2008). An automatic cloud mask algorithm based on time series of MODIS measurements. *Journal of Geophysical Research*, 113(D16), D16207. <https://doi.org/10.1029/2007JD009641>
- Macor, J. L. (2007). *Développement de techniques de prévision de pluie basées sur les propriétés multi-échelles des données radar et satellites* [Ecole des Ponts ParisTech]. <https://pastel.archives-ouvertes.fr/pastel-00003420/>
- Magnussen, S., Boudewyn, P., & Wulder, M. (2004). Contextual classification of Landsat TM images to forest inventory cover types. *International Journal of Remote Sensing*, 25(12), 2421-2440. <https://doi.org/10.1080/01431160310001642296>
- Malbêteau, Y., Merlin, O., Gascoin, S., Gastellu, J. P., Mattar, C., Olivera-Guerra, L., Khabba, S., & Jarlan, L. (2017). Normalizing land surface temperature data for elevation and illumination effects in mountainous areas : A case study using ASTER data over a steep-sided valley in Morocco. *Remote Sensing of Environment*, 189, 25-39. <https://doi.org/10.1016/j.rse.2016.11.010>
- Malbêteau, Yoann, Merlin, O., Molero, B., Rüdiger, C., & Bacon, S. (2016). DisPATCh as a tool to evaluate coarse-scale remotely sensed soil moisture using localized in situ measurements : Application to SMOS and AMSR-E data in Southeastern Australia. *International Journal of Applied Earth Observation and Geoinformation*, 45, 221-234. <https://doi.org/10.1016/j.jag.2015.10.002>
- Mallet, C., & Bretar, F. (2009). Full-waveform topographic lidar : State-of-the-art. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1), 1-16. <https://doi.org/10.1016/j.isprsjprs.2008.09.007>
- Manabe, S. (1969). CLIMATE AND THE OCEAN CIRCULATION <sup>1</sup> : I. THE ATMOSPHERIC CIRCULATION AND THE HYDROLOGY OF THE EARTH'S SURFACE. *Monthly Weather Review*, 97(11), 739-774. [https://doi.org/10.1175/1520-0493\(1969\)097<0739:CATOC>2.3.CO;2](https://doi.org/10.1175/1520-0493(1969)097<0739:CATOC>2.3.CO;2)



- Mandelbrot, B. (1967). How long is the coast of Britain ? Statistical self-similarity and fractional dimension. *Science*, 156(3775), 636-638.
- Mandelbrot, B. (1974). Intermittent turbulence in self-similar cascades : Divergence of high moments and dimension of the carrier. *Journal of Fluid Mechanics*, 62(2), 331-358.
- Mandelbrot, B. B. (1975). Stochastic models for the Earth's relief, the shape and the fractal dimension of the coastlines, and the number-area rule for islands. *Proceedings of the National Academy of Sciences*, 72(10), 3825-3828. <https://doi.org/10.1073/pnas.72.10.3825>
- Mandelbrot, BENOIT B., & Van Ness, J. W. (1968). Fractional Brownian motions, fractional. *Geophys. Res. Lett*, 24, 2099–2102. <https://pdfs.semanticscholar.org/6a8f/dcdf9eaaf2145252f0a4ee6520ef2cf3f476.pdf>
- Manfreda, S., McCabe, M. F., Fiorentino, M., Rodríguez-Iturbe, I., & Wood, E. F. (2007). Scaling characteristics of spatial patterns of soil moisture from distributed modelling. *Advances in Water Resources*, 30(10), 2145-2150. <https://doi.org/10.1016/j.advwatres.2006.07.009>
- Mangiarotti, S., Drapeau, L., & Letellier, C. (2014). Two chaotic global models for cereal crops cycles observed from satellite in northern Morocco. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 24(2), 023130.
- Mangiarotti, S., & Huc, M. (2019). Can the original equations of a dynamical system be retrieved from observational time series? *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 29(2), 023133.
- Mangiarotti, S., Mazzega, P., Hiernaux, P., & Mougin, E. (2010). The Vegetation dynamics in West Africa from AVHRR-NDVI data : Horizons of predictability versus spatial scales. *Remote Sensing of Environment*, 114(9), 2036-2047.
- Mangiarotti, S., Mazzega, P., Hiernaux, P., & Mougin, E. (2012). Predictability of vegetation cycles over the semi-arid region of Gourma (Mali) from forecasts of AVHRR-NDVI signals. *Remote Sensing of Environment*, 123, 246-257. <https://doi.org/10.1016/j.rse.2012.03.011>
- Mangiarotti, S., & Schoenauer, M. (2011). *Identification des paramètres du modèle de Lorenz en contexte perturbé, par une approche de stratégie d'évolution*. 14, 109-114.
- Mangiarotti, S., Sharma, A. K., Corgne, S., Hubert-Moy, L., Ruiz, L., Sekhar, M., & Kerr, Y. (2018). Can the global modeling technique be used for crop classification? *Chaos, Solitons & Fractals*, 106, 363-378. <https://doi.org/10.1016/j.chaos.2017.12.003>
- Mangiarotti, Sylvain, Le Jean, F., Huc, M., & Letellier, C. (2016). Global modeling of aggregated and associated chaotic dynamics. *Chaos, Solitons & Fractals*, 83, 82-96. <https://doi.org/10.1016/j.chaos.2015.11.031>
- Manivasagam, V. S., Kaplan, G., & Rozenstein, O. (2019). Developing Transformation Functions for VENμS and Sentinel-2 Surface Reflectance over Israel. *Remote Sensing*, 11(14), 1710. <https://doi.org/10.3390/rs11141710>
- Mark, D. M., & Aronson, P. B. (1984). Scale-dependent fractal dimensions of topographic surfaces : An empirical investigation, with applications in geomorphology and computer mapping. *Journal of the International Association for Mathematical Geology*, 16(7), 671-683. <https://doi.org/10.1007/BF01033029>

- Marshall, J. S., & Palmer, W. M. K. (1948). The distribution of raindrops with size. *Journal of meteorology*, 5(4), 165-166.
- Martimort, P., Arino, O., Berger, M., Biasutti, R., Carnicero, B., Del Bello, U., Fernandez, V., Gascon, F., Greco, B., Silvestrin, P., Spoto, F., & Sy, O. (2007). Sentinel-2 optical high resolution mission for GMES operational services. *2007 IEEE International Geoscience and Remote Sensing Symposium*, 2677-2680. <https://doi.org/10.1109/IGARSS.2007.4423394>
- Martinuzzi, S., Gould, W. A., & Ramos Gonzalez, O. M. (2007). *Creating cloud-free Landsat ETM+ data sets in tropical landscapes : Cloud and cloud-shadow removal* (IITF-GTR-32; p. IITF-GTR-32). U.S. Department of Agriculture, Forest Service, International Institute of Tropical Forestry. <https://doi.org/10.2737/IITF-GTR-32>
- Mascaro, G., & Vivoni, E. R. (2012). Comparison of Statistical and Multifractal Properties of Soil Moisture and Brightness Temperature From ESTAR and PSR During SGP99. *IEEE Geoscience and Remote Sensing Letters*, 9(3), 373-377. <https://doi.org/10.1109/LGRS.2011.2169770>
- Mascaro, G., Vivoni, E. R., & Deidda, R. (2010). Downscaling soil moisture in the southern Great Plains through a calibrated multifractal model for land surface modeling applications : DOWNSCALING SOIL MOISTURE IN THE GREAT PLAINS. *Water Resources Research*, 46(8). <https://doi.org/10.1029/2009WR008855>
- Mausser, W., & Schädlich, S. (1998). Modelling the spatial distribution of evapotranspiration on different scales using remote sensing data. *Journal of Hydrology*, 212-213, 250-267. [https://doi.org/10.1016/S0022-1694\(98\)00228-5](https://doi.org/10.1016/S0022-1694(98)00228-5)
- Merlin, O., Al Bitar, A., Walker, J. P., & Kerr, Y. (2010a). An improved algorithm for disaggregating microwave-derived soil moisture based on red, near-infrared and thermal-infrared data. *Remote Sensing of Environment*, 114(10), 2305-2316. <https://doi.org/10.1016/j.rse.2010.05.007>
- Merlin, O., Escorihuela, M. J., Mayoral, M. A., Hagolle, O., Al Bitar, A., & Kerr, Y. (2013). Self-calibrated evaporation-based disaggregation of SMOS soil moisture : An evaluation study at 3km and 100m resolution in Catalunya, Spain. *Remote Sensing of Environment*, 130, 25-38. <https://doi.org/10.1016/j.rse.2012.11.008>
- Merlin, O., Malbêteau, Y., Notfi, Y., Bacon, S., Khabba, S., & Jarlan, L. (2015). Performance Metrics for Soil Moisture Downscaling Methods : Application to DISPATCH Data in Central Morocco. *Remote Sensing*, 7(4), 3783-3807. <https://doi.org/10.3390/rs70403783>
- Merlin, O., Rudiger, C., Al Bitar, A., Richaume, P., Walker, J. P., & Kerr, Y. H. (2012). Disaggregation of SMOS Soil Moisture in Southeastern Australia. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1556-1571. <https://doi.org/10.1109/TGRS.2011.2175000>
- Merlin, O., Rudiger, C., Richaume, P., Al Bitar, A., Mialon, A., Walker, J. P., & Kerr, Y. (2010b). Disaggregation as a top-down approach for evaluating 40 km resolution SMOS data using point-scale measurements : Application to AACES-1. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XII*, 7824.
- Merlin, O., Stefan, V. G., Amazirh, A., Chanzy, A., Ceschia, E., Er-Raki, S., Gentine, P., Tallec, T., Ezzahar, J., Bircher, S., Beringer, J., & Khabba, S. (2016). Modeling soil evaporation efficiency in a range of soil and atmospheric conditions using a meta-analysis approach : MODELING

- SOIL EVAPORATION EFFICIENCY. *Water Resources Research*, 52(5), 3663-3684.  
<https://doi.org/10.1002/2015WR018233>
- Merlin, O., Walker, J., Chehbouni, A., & Kerr, Y. (2008). Towards deterministic downscaling of SMOS soil moisture using MODIS derived soil evaporative efficiency. *Remote Sensing of Environment*, 112(10), 3935-3946. <https://doi.org/10.1016/j.rse.2008.06.012>
- Merlin, O., Walker, J. P., Kalma, J. D., Kim, E. J., Hacker, J., Panciera, R., Young, R., Summerell, G., Hornbuckle, J., Hafeez, M., & Jackson, T. (2008). The NAFE'06 data set : Towards soil moisture retrieval at intermediate resolution. *Advances in Water Resources*, 31(11), 1444-1455.  
<https://doi.org/10.1016/j.advwatres.2008.01.018>
- Mohanty, B. P., & Skaggs, T. H. (2001). Spatio-temporal evolution and time-stable characteristics of soil moisture within remote sensing footprints with varying soil, slope, and vegetation. *Advances in Water Resources*, 24(9-10), 1051-1067. [https://doi.org/10.1016/S0309-1708\(01\)00034-3](https://doi.org/10.1016/S0309-1708(01)00034-3)
- Molero, B. (2018). *CATDS Level 4 Disaggregation Processor (C4DIS) : Algorithms & Prototype Description Document*.
- Molero, B., Leroux, D. J., Richaume, P., Kerr, Y. H., Merlin, O., Cosh, M. H., & Bindlish, R. (2018). Multi-Timescale Analysis of the Spatial Representativeness of In Situ Soil Moisture Data within Satellite Footprints : Soil Moisture Time and Spatial Scales. *Journal of Geophysical Research: Atmospheres*, 123(1), 3-21. <https://doi.org/10.1002/2017JD027478>
- Molero, B., Merlin, O., Malbêteau, Y., Al Bitar, A., Cabot, F., Stefan, V., Kerr, Y., Bacon, S., Cosh, M. H., Bindlish, R., & Jackson, T. J. (2016). SMOS disaggregated soil moisture product at 1 km resolution : Processor overview and first validation results. *Remote Sensing of Environment*, 180, 361-376. <https://doi.org/10.1016/j.rse.2016.02.045>
- Montzka, C., Jagdhuber, T., Horn, R., Bogen, H. R., Hajnsek, I., Reigber, A., & Vereecken, H. (2016). Investigation of SMAP Fusion Algorithms With Airborne Active and Passive L-Band Microwave Remote Sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 54(7), 3878-3889.  
<https://doi.org/10.1109/TGRS.2016.2529659>
- Moran, M. S., Clarke, T. R., Inoue, Y., & Vidal, A. (1994). Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sensing of Environment*, 49(3), 246-263. [https://doi.org/10.1016/0034-4257\(94\)90020-5](https://doi.org/10.1016/0034-4257(94)90020-5)
- Narayan, U., Lakshmi, V., & Jackson, T. J. (2006). High-resolution change estimation of soil moisture using L-band radiometer and Radar observations made during the SMEX02 experiments. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6), 1545-1554.  
<https://doi.org/10.1109/TGRS.2006.871199>
- Navarro, A., Rolim, J., Miguel, I., Catalão, J., Silva, J., Painho, M., & Vekerdy, Z. (2016). Crop Monitoring Based on SPOT-5 Take-5 and Sentinel-1A Data for the Estimation of Crop Water Requirements. *Remote Sensing*, 8(6), 525. <https://doi.org/10.3390/rs8060525>
- Neuhauser, M., Verrier, S., Merlin, O., Molero, B., Suere, C., & Mangiarotti, S. (2019). Multi-scale statistical properties of disaggregated SMOS soil moisture products in Australia. *Advances in Water Resources*, 18. <https://doi.org/10.1016/j.advwatres.2019.103426>

- Njoku, E. G., Jackson, T. J., Lakshmi, V., Chan, T. K., & Nghiem, S. V. (2003). Soil moisture retrieval from AMSR-E. *IEEE Transactions on Geoscience and Remote Sensing*, 41(2), 215-229. <https://doi.org/10.1109/TGRS.2002.808243>
- Njoku, E. G., Wilson, W. J., Yueh, S. H., Dinardo, S. J., Li, F. K., Jackson, T. J., Lakshmi, V., & Bolten, J. (2002). Observations of soil moisture using a passive and active low-frequency microwave airborne sensor during SGP99. *IEEE Transactions on Geoscience and Remote Sensing*, 40(12), 2659-2673. <https://doi.org/10.1109/TGRS.2002.807008>
- Nogueira, M. (2017). Exploring the link between multiscale entropy and fractal scaling behavior in near-surface wind. *PloS one*, 12(3), e0173994. <http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0173994>
- Norton, C. L., Brooks, G. C., & Welch, R. (1977). Optical and Modulation Transfer Function. *Photogrammetric Engineering and Remote Sensing*, 43, 613-636.
- Nuninger, L., Oštir, K., Kokalj, Z., & Marsetic, A. (2008). *Lidor. Acquisition, traitement et analyse d'images LiDAR pour la modélisation des paléo-reliefs de la plaine littorale du Languedoc oriental*. 96.
- Oboukhov, A. M. (1962). Some specific features of atmospheric turbulence. *Journal of Fluid Mechanics*, 13(01), 77. <https://doi.org/10.1017/S0022112062000506>
- Ochsner, T. E., Cosh, M. H., Cuenca, R. H., Dorigo, W. A., Draper, C. S., Hagimoto, Y., Kerr, Y. H., Njoku, E. G., Small, E. E., & Zreda, M. (2013). State of the Art in Large-Scale Soil Moisture Monitoring. *Soil Science Society of America Journal*, 77(6), 1888. <https://doi.org/10.2136/sssaj2013.03.0093>
- Ogor, B., & Kpalma, K. (1996). Le traitement morphologique des images satellites : Une approche hiérarchique par région. *CARI'96*, 497-510.
- Ojha, N., Merlin, O., Molero, B., Suere, C., Olivera-Guerra, L., Ait Hssaine, B., Amazirh, A., Al Bitar, A., Escorihuela, M., & Er-Raki, S. (2019). Stepwise Disaggregation of SMAP Soil Moisture at 100 m Resolution Using Landsat-7/8 Data and a Varying Intermediate Resolution. *Remote Sensing*, 11(16), 1863. <https://doi.org/10.3390/rs11161863>
- Oldak, A., Pachepsky, Y., Jackson, T. J., & Rawls, W. J. (2002). Statistical properties of soil moisture images revisited. *Journal of Hydrology*, 255(1-4), 12-24. [https://doi.org/10.1016/S0022-1694\(01\)00507-8](https://doi.org/10.1016/S0022-1694(01)00507-8)
- Oliva, R., Daganzo, E., Kerr, Y. H., Mecklenburg, S., Nieto, S., Richaume, P., & Gruhier, C. (2012). SMOS Radio Frequency Interference Scenario : Status and Actions Taken to Improve the RFI Environment in the 1400–1427-MHz Passive Band. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1427-1439. <https://doi.org/10.1109/TGRS.2012.2182775>
- O'Neill, R. V., Deangelis, D. L., Waide, J. B., Allen, T. F., & Allen, G. E. (1986). *A hierarchical concept of ecosystems* (Princeton University Press).
- Owe, M., de Jeu, R., & Walker, J. (2001). A methodology for surface soil moisture and vegetation optical depth retrieval using the microwave polarization difference index. *IEEE Transactions on Geoscience and Remote Sensing*, 39(8), 1643-1654. <https://doi.org/10.1109/36.942542>

- Ozuysal, M. (2018). Ground texture classification with deep learning. *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4.  
<https://doi.org/10.1109/SIU.2018.8404717>
- Painter, S., & Paterson, L. (1994). Fractional Lévy motion as a model for spatial variability in sedimentary rock. *Geophysical Research Letters*, 21(25), 2857-2860.  
<https://doi.org/10.1029/94GL02035>
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222. <https://doi.org/10.1080/01431160412331269698>
- Panciera, R., Walker, J. P., Jackson, T. J., Gray, D. A., Tanase, M. A., Ryu, D., Monerris, A., Yardley, H., Rudiger, C., Wu, X., Gao, Y., & Hacker, J. M. (2014). The Soil Moisture Active Passive Experiments (SMAPEX) : Toward Soil Moisture Retrieval From the SMAP Mission. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1), 490-507.  
<https://doi.org/10.1109/TGRS.2013.2241774>
- Paola, J. D., & Schowengerdt, R. A. (1995). A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery. *International Journal of Remote Sensing*, 16(16), 3033-3058. <https://doi.org/10.1080/01431169508954607>
- Parisi, G., & Frisch, U. (1985). A multifractal model of intermittency. *Turbulence and Predictability in Geophysical Fluid Dynamics and Climate Dynamics*, 84-88.
- Pecknold, S., Lovejoy, S., Schertzer, D., Hooge, C., & Malouin, J. F. (1993). *The simulation of universal multifractals*.
- Peischl, S., Walker, J. P., Rüdiger, C., Ye, N., Kerr, Y. H., Kim, E., Bandara, R., & Allahmoradi, M. (2012). The AACES field experiments : SMOS calibration and validation across the Murrumbidgee River catchment. *Hydrology and Earth System Sciences*, 16(6), 1697-1708.  
<https://doi.org/10.5194/hess-16-1697-2012>
- Pellenq, J., Kalma, J., Boulet, G., Saulnier, G.-M., Wooldridge, S., Kerr, Y., & Chehbouni, A. (2003). A disaggregation scheme for soil moisture based on topography and soil depth. *Journal of Hydrology*, 276(1-4), 112-127. [https://doi.org/10.1016/S0022-1694\(03\)00066-0](https://doi.org/10.1016/S0022-1694(03)00066-0)
- Pelletier, C. (2016). *Traitements des images appliqués à l'observation de la Terre*.
- Peng, J., Loew, A., Merlin, O., & Verhoest, N. E. C. (2017). A review of spatial downscaling of satellite remotely sensed soil moisture : Downscale Satellite-Based Soil Moisture. *Reviews of Geophysics*, 55(2), 341-366. <https://doi.org/10.1002/2016RG000543>
- Peng, J., Loew, A., Zhang, S., Wang, J., & Niesel, J. (2016). Spatial Downscaling of Satellite Soil Moisture Data Using a Vegetation Temperature Condition Index. *IEEE Transactions on Geoscience and Remote Sensing*, 54(1), 558-566.  
<https://doi.org/10.1109/TGRS.2015.2462074>
- Pentland, A. P. (1984). Fractal-based description of natural scenes. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 6, 661-674.
- Petropoulos, G. P., Ireland, G., & Barrett, B. (2015). Surface soil moisture retrievals from remote sensing : Current status, products & future trends. *Physics and Chemistry of the Earth, Parts A/B/C*, 83-84, 36-56. <https://doi.org/10.1016/j.pce.2015.02.009>

- Piles, M., Entekhabi, D., & Camps, A. (2009). A Change Detection Algorithm for Retrieving High-Resolution Soil Moisture From SMAP Radar and Radiometer Observations. *IEEE Transactions on Geoscience and Remote Sensing*, 47(12), 4125-4131.  
<https://doi.org/10.1109/TGRS.2009.2022088>
- Piles, María, Camps, A., Vall-Ilossera, M., Corbella, I., Panciera, R., Rudiger, C., Kerr, Y. H., & Walker, J. (2011). Downscaling SMOS-Derived Soil Moisture Using MODIS Visible/Infrared Data. *IEEE Transactions on Geoscience and Remote Sensing*, 49(9), 3156-3166.  
<https://doi.org/10.1109/TGRS.2011.2120615>
- Planck, M. (1901). *On the Law of Distribution of Energy in the Normal Spectrum*. 11.
- Polidori, L. (2006). *Introduction à la télédétection spatiale* [Manuel de cours, École Supérieure des Géomètres Topographes].
- Ponti, M. P. (2013). Segmentation of Low-Cost Remote Sensing Images Combining Vegetation Indices and Mean Shift. *IEEE Geoscience and Remote Sensing Letters*, 10(1), 67-70.  
<https://doi.org/10.1109/LGRS.2012.2193113>
- Puissant, A., Hirsch, J., & Weber, C. (2005). The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. *International Journal of Remote Sensing*, 26(4), 733-745. <https://doi.org/10.1080/01431160512331316838>
- Qiu, H.-L., Lam, N. S.-N., Quattrochi, D., & Gamon, A. J. (1999). Fractal characterization of hyperspectral imagery. *Photogrammetric Engineering and Remote Sensing*, 65, 63-71.
- Rahman, H., & Dedieu, G. (1994). SMAC : A simplified method for the atmospheric correction of satellite measurements in the solar spectrum. *International Journal of Remote Sensing*, 15(1), 123-143. <https://doi.org/10.1080/01431169408954055>
- Rayleigh, J. W. S. B. (1871). *On the scattering of light by small particles*.
- Rebora, N., Ferraris, L., Von Hardenberg, J., & Provenzale, A. (2006). Rainfall downscaling and flood forecasting : A case study in the Mediterranean area. *Natural Hazards and Earth System Science*, 6(4), 611-619. <https://hal.archives-ouvertes.fr/hal-00299348/>
- Reichenbach, S. E. (1991). Characterizing digital image acquisition devices. *Optical Engineering*, 30(2), 170. <https://doi.org/10.1117/12.55783>
- Reuter, M., & Fischer, J. (2004). Identification of cloudy and clear sky areas in SEVIRI Images. *Proceedings in Geophysical Research Abstracts*. EGU Conf.
- Richardson, L. F. (1922). *Weather prediction by numerical process*. Cambridge Univ. Press.
- Richman, J. S., & Moorman, J. R. (2000). Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology*, 278(6), H2039-H2049. <https://doi.org/10.1152/ajpheart.2000.278.6.H2039>
- Richter, R., Bachmann, M., Dorigo, W., & Muller, A. (2006). Influence of the Adjacency Effect on Ground Reflectance Measurements. *IEEE Geoscience and Remote Sensing Letters*, 3(4), 565-569. <https://doi.org/10.1109/LGRS.2006.882146>
- Richter, R., Schläpfer, D., & Müller, A. (2006). An automatic atmospheric correction algorithm for visible/NIR imagery. *International Journal of Remote Sensing*, 27(10), 2077-2085.  
<https://doi.org/10.1080/01431160500486690>



- Robinson, D. A., Campbell, C. S., Hopmans, J. W., Hornbuckle, B. K., Jones, S. B., Knight, R., Ogden, F., Selker, J., & Wendroth, O. (2008). Soil moisture measurement for ecological and hydrological watershed-scale observatories : A review. *Vadose Zone Journal*, 7(1), 358-389.
- Robock, A., Vinnikov, K. Y., Srinivasan, G., Entin, J. K., Hollinger, S. E., Speranskaya, N. A., Liu, S., & Namkhai, A. (2000). The Global Soil Moisture Data Bank. *Bulletin of the American Meteorological Society*, 81(6), 1281-1299. [https://doi.org/10.1175/1520-0477\(2000\)081<1281:TGSMDB>2.3.CO;2](https://doi.org/10.1175/1520-0477(2000)081<1281:TGSMDB>2.3.CO;2)
- Rodriguez-Iturbe, I., Vogel, G. K., Rigon, R., Entekhabi, D., Castelli, F., & Rinaldo, A. (1995). On the spatial organization of soil moisture fields. *Geophysical Research Letters*, 22(20), 2757-2760. <https://doi.org/10.1029/95GL02779>
- Rosenfeld, A. (s. d.). Picture processing : 1980. *Computer Graphics and Image Processing*, 16(1), 52-89.
- Rötzer, K., Montzka, C., & Vereecken, H. (2015). Spatio-temporal variability of global soil moisture products. *Journal of Hydrology*, 522, 187-202. <https://doi.org/10.1016/j.jhydrol.2014.12.038>
- Rouquié, B., Hagolle, O., Bréon, F.-M., Boucher, O., Desjardins, C., & Rémy, S. (2017). Using Copernicus Atmosphere Monitoring Service Products to Constrain the Aerosol Type in the Atmospheric Correction Processor MAJA. *Remote Sensing*, 9(12), 1230. <https://doi.org/10.3390/rs9121230>
- Roy, A. G., Gravel, G., & Gauthier, C. (1987). Measuring the dimension of surfaces : A review and appraisal of different methods. *Proceedings of the 8th International Symposium on Computer-Assisted Cartography (Auto-Carto 8)*, 68-77.
- Roy, D. P., Wulder, M. A., Loveland, T. R., C.E., W., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindaschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z. (2014). Landsat-8 : Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154-172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Royer, A., O'Neill, N. T., Davis, A., & Hubert, L. (1988). Comparison of radiative transfer models used to determine atmospheric optical parameters from space. *Modeling of the Atmosphere*, 928, 118-135.
- Ryu, D., & Famiglietti, J. S. (2006). Multi-scale spatial correlation and scaling behavior of surface soil moisture. *Geophysical Research Letters*, 33(8), L08404. <https://doi.org/10.1029/2006GL025831>
- Saunders, R. W., & Kriebel, K. T. (1988). An improved method for detecting clear sky and cloudy radiances from AVHRR data. *International Journal of Remote Sensing*, 9(1), 123-150. <https://doi.org/10.1080/01431168808954841>
- Sayer, A. M., Hsu, N. C., Bettenhausen, C., & Jeong, M.-J. (2013). Validation and uncertainty estimates for MODIS Collection 6 "Deep Blue" aerosol data : DEEP BLUE COLLECTION 6 VALIDATION. *Journal of Geophysical Research: Atmospheres*, 118(14), 7864-7872. <https://doi.org/10.1002/jgrd.50600>
- Schertzer, D., & Lovejoy, S. (1984). On the Dimension of Atmospheric motions. *Turbulence and Chaotic phenomena in Fluids*, 505-512.



- Schertzer, D., & Lovejoy, S. (1987). Physical modeling and analysis of rain and clouds by anisotropic scaling multiplicative processes. *Journal of Geophysical Research*, 92(D8), 9693. <https://doi.org/10.1029/JD092iD08p09693>
- Schertzer, D., & Lovejoy, S. (1991). Nonlinear geodynamical variability : Multiple singularities, universality and observables. *Non-Linear Variability in Geophysics*, 41-82.
- Schertzer, D., & Lovejoy, S. (1997). Universal multifractals do exist! : Comments on “A statistical analysis of mesoscale rainfall as a random cascade”. *Journal of Applied Meteorology*, 36(9), 1296–1303.
- Schertzer, D., Lovejoy, S., & Hubert, P. (2002). An introduction to stochastic multifractal fields. *ISFMA Symposium on Environmental Science and Engineering with related Mathematical Problems*, 106–179. <http://132.206.6.11/~gang/eprints/Paris.eprints/Stochastic.multi.eprint2002.pdf>
- Schmitt, F. (1993). Estimation of universal multifractal indices for atmospheric turbulent velocity fields. *Fractals*, 1(3), 568-575.
- Sellami, M., Chaabane, F., & Fetita, C. (2008). Morphological Segmentation of Multispectral Images for Land Cover Mapping. *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, III-326-III-329. <https://doi.org/10.1109/IGARSS.2008.4779349>
- Sellers, P. J., Mintz, Y. C. S. Y., Sud, Y. E. A., & Dalcher, A. (1986). A simple biosphere model (SiB) for use within general circulation models. *Journal of the Atmospheric Sciences*, 43(6), 505-531.
- Seuront, L., Schmitt, F., Lagadeuc, Y., Schertzer, D., Lovejoy, S., & Frontier, S. (1996). Multifractal analysis of phytoplankton biomass and temperature in the ocean. *Geophysical Research Letters*, 23(24), 3591-3594.
- Sharma, D. (2007). Spatial disaggregation of bias-corrected GCM precipitation for improved hydrologic simulation : Ping River Basin, Thailand. *Hydrol. Earth Syst. Sci.*, 19.
- She, Z.-S., & Leveque, E. (1994). Universal Scaling Laws in Fully Developed Turbulence. *Physical review letters*, 72(3).
- Shelberg, M. C., Lam, N., & Moellering, H. (1983). *Measuring the Fractal Dimensions of Surfaces*: Defense Technical Information Center. <https://doi.org/10.21236/ADA129664>
- Shelberg, M. C., Moellering, H., & Lam, N. S.-N. (1982). Measuring the fractal dimensions of empirical cartographic curves. *Proceedings, Fifth International Symposium on Computer-Assisted Cartography (Auto-Carto 5)*, 481-490.
- Si, B. C. (2008). Spatial Scaling Analyses of Soil Physical Properties : A Review of Spectral and Wavelet Methods. *Vadose Zone Journal*, 7(2), 547. <https://doi.org/10.2136/vzj2007.0040>
- Siebesma, A. P., & Jonker, H. J. J. (2000). Anomalous Scaling of Cumulus Cloud Boundaries. *Physical Review Letters*, 85(1), 214-217. <https://doi.org/10.1103/PhysRevLett.85.214>
- Silva, L E V, Filho, A. C. S. S., Fazan, V. P. S., Felipe, J. C., & Junior, L. O. M. (2016). Two-dimensional sample entropy : Assessing image texture through irregularity. *Biomedical Physics & Engineering Express*, 2(4), 045002. <https://doi.org/10.1088/2057-1976/2/4/045002>
- Silva, Luiz E.V., Duque, J. J., Felipe, J. C., Murta Jr, L. O., & Humeau-Heurtier, A. (2018). Two-dimensional multiscale entropy analysis : Applications to image texture evaluation. *Signal Processing*, 147, 224-232. <https://doi.org/10.1016/j.sigpro.2018.02.004>

- Simard, M., Saatchi, S. S., & De Grandi, G. (2000). The use of decision tree and multiscale texture for classification of JERS-1 SAR data over tropical forest. *IEEE Transactions on Geoscience and Remote Sensing*, 38(5), 2310-2321. <https://doi.org/10.1109/36.868888>
- Smith, A. B., Walker, J. P., Western, A. W., Young, R. I., Ellett, K. M., Pipunic, R. C., Grayson, R. B., Siriwardena, L., Chiew, F. H. S., & Richter, H. (2012). The Murrumbidgee soil moisture monitoring network data set : DATA AND ANALYSIS NOTE. *Water Resources Research*, 48(7). <https://doi.org/10.1029/2012WR011976>
- Smith, L. C. (1997). Satellite remote sensing of river inundation area, stage, and discharge : A review. *HYDROLOGICAL PROCESSES*, 11, 13.
- Sobrino, J. A., Del Frate, F., Drusch, M., Jimenez-Munoz, J. C., Manunta, P., & Regan, A. (2016). Review of Thermal Infrared Applications and Requirements for Future High-Resolution Sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 54(5), 2963-2972. <https://doi.org/10.1109/TGRS.2015.2509179>
- Soh, L.-K., & Tsatsoulis, C. (1999). Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. *IEEE Transactions on Geoscience and Remote Sensing*, 37(2), 780-795. <https://doi.org/10.1109/36.752194>
- Sohrabinia, M. (2012). *Find pixel indices in HDF-EOS files based on LatLon coordinates*. <https://fr.mathworks.com/matlabcentral/fileexchange/37033-find-pixel-indices-in-hdf-eos-files-based-on-latlon-coordinates>
- Song, C., Jia, L., & Menenti, M. (2014). Retrieving High-Resolution Surface Soil Moisture by Downscaling AMSR-E Brightness Temperature Using MODIS LST and NDVI Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(3), 935-942. <https://doi.org/10.1109/JSTARS.2013.2272053>
- Stoian, A., Poulain, V., Inglada, J., Poughon, V., & Derksen, D. (2019). Land Cover Maps Production with High Resolution Satellite Image Time Series and Convolutional Neural Networks : Adaptations and Limits for Operational Systems. *Remote Sensing*, 11(17), 1986. <https://doi.org/10.3390/rs11171986>
- St-Onge, B. A., & Cavayas, F. (1995). Estimating forest stand structure from high resolution imagery using the directional variogram. *International Journal of Remote Sensing*, 16(11), 1999-2021. <https://doi.org/10.1080/01431169508954535>
- Stumpf, A., Malet, J.-P., Allemand, P., & Ulrich, P. (2014). Surface reconstruction and landslide displacement measurements with Pléiades satellite images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 95, 1-12. <https://doi.org/10.1016/j.isprsjprs.2014.05.008>
- Talleg, T., Béziat, P., Jarosz, N., Rivalland, V., & Ceschia, E. (2013). Crops' water use efficiencies in temperate climate : Comparison of stand, ecosystem and agronomical approaches. *Agricultural and Forest Meteorology*, 168, 69-81. <https://doi.org/10.1016/j.agrformet.2012.07.008>
- Tamura, H., Mori, S., & Yamawaki, T. (1978). Textural Features Corresponding to Visual Perception. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(6), 460-473. <https://doi.org/10.1109/TSMC.1978.4309999>

- Tanré, D., Deroo, C., Duhaut, P., Herman, M., Morcrette, J. J., Perbos, J., & Deschamps, P. Y. (1986). *Simulation of the satellite signal in the solar spectrum : User's Guide*. Lille: LOA.
- Tanré, D., Deroo, C., Duhaut, P., Herman, M., Morcrette, J. J., Perbos, J., & Deschamps, P. Y. (1990). Description of a computer code to simulate the satellite signal in the solar spectrum : The 5S code. *International Journal of Remote Sensing*, 11(4), 659-668. <https://doi.org/10.1080/01431169008955048>
- Tanré, D., Deschamps, P. Y., Devaux, C., & Herman, M. (1988). Estimation of Saharan aerosol optical thickness from blurring effects in thematic mapper data. *Journal of Geophysical Research*, 93(D12), 15955. <https://doi.org/10.1029/JD093iD12p15955>
- Tanré, D., Deschamps, P. Y., Duhaut, P., & Herman, M. (1987). Adjacency effect produced by the atmospheric scattering in thematic mapper data. *Journal of Geophysical Research*, 92(D10), 12000. <https://doi.org/10.1029/JD092iD10p12000>
- Tarquis, A. M., Platonov, A., Matulka, A., Grau, J., Sekula, E., Diez, M., & Redondo, J. M. (2014). Application of multifractal analysis to the study of SAR features and oil spills on the ocean surface. *Nonlinear Processes in Geophysics*, 21(2), 439-450. <https://doi.org/10.5194/npg-21-439-2014>
- Tessier, Y., Lovejoy, S., & Schertzer, D. (1993). *Universal Multifractals : Theory and Observations for Rain and Clouds*. <https://doi.org/10.1175/1520-0450>
- Thomas, N., Hendrix, C., & Congalton, R. G. (2003). A Comparison of Urban Mapping Methods Using High-Resolution Digital Imagery. *Photogrammetric Engineering & Remote Sensing*, 69(9), 963-972. <https://doi.org/10.14358/PERS.69.9.963>
- Torrence, C., & Compo, G. P. (1998). A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*, 79(1), 61-78.
- Tucker, C. J., & Sellers, P. J. (1986). Satellite remote sensing of primary production. *International Journal of Remote Sensing*, 7(11), 1395-1416. <https://doi.org/10.1080/01431168608948944>
- Tupin, F., Nicolas, J.-M., & Inglada, J. (2014). *Imagerie de télédétection*. Lavoisier : Hermès Sciences.
- Turner, R. E., & Spencer, M. M. (1972). Atmospheric model for the correction of spacecraft data. *Proceeding of the 8th International Symposium on Remote Sensing of Environment*, 895-934.
- Usovich, B., Lipiec, J., & Lukowski, M. (2019). Evaluation of Soil Moisture Variability in Poland from SMOS Satellite Observations. *Remote Sensing*, 11(11), 1280. <https://doi.org/10.3390/rs11111280>
- Vereecken, H., Huisman, J. A., Pachepsky, Y., Montzka, C., van der Kruk, J., Bogaen, H., Weihermüller, L., Herbst, M., Martinez, G., & Vanderborght, J. (2014). On the spatio-temporal dynamics of soil moisture at the field scale. *Journal of Hydrology*, 516, 76-96. <https://doi.org/10.1016/j.jhydrol.2013.11.061>
- Verhoest, N. E. C., van den Berg, M. J., Martens, B., Lievens, H., Wood, E. F., Pan, M., Kerr, Y. H., Al Bitar, A., Tomer, S. K., Drusch, M., Vernieuwe, H., De Baets, B., Walker, J. P., Dumedah, G., & Pauwels, V. R. N. (2015). Copula-Based Downscaling of Coarse-Scale Soil Moisture Observations With Implicit Bias Correction. *IEEE Transactions on Geoscience and Remote Sensing*, 53(6), 3507-3521. <https://doi.org/10.1109/TGRS.2014.2378913>

- Vermote, E. F., Tanre, D., Deuze, J. L., Herman, M., & Morcette, J.-J. (1997). Second Simulation of the Satellite Signal in the Solar Spectrum, 6S : An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 35(3), 675-686. <https://doi.org/10.1109/36.581987>
- Verrier, S., de Montera, L., Barthès, L., & Mallet, C. (2010). Multifractal analysis of African monsoon rain fields, taking into account the zero rain-rate problem. *Journal of Hydrology*, 389(1-2), 111-120. <https://doi.org/10.1016/j.jhydrol.2010.05.035>
- Verrier, S., Mallet, C., & Barthès, L. (2011). Multiscaling properties of rain in the time domain, taking into account rain support biases. *Journal of Geophysical Research*, 116(D20). <https://doi.org/10.1029/2011JD015719>
- Verrier, Sébastien. (2011). *Modélisation de la variabilité spatiale et temporelle des précipitations à la sub-mésoéchelle par une approche multifractale* [Université de Versailles-Saint Quentin en Yvelines]. <https://hal-sde.archives-ouvertes.fr/tel-00734327/>
- Verrier, Sébastien, Barthès, L., & Mallet, C. (2013). Theoretical and empirical scale dependency of Z-R relationships : Evidence, impacts, and correction: SCALE DEPENDENCY OF Z-R RELATIONSHIPS. *Journal of Geophysical Research: Atmospheres*, 118(14), 7435-7449. <https://doi.org/10.1002/jgrd.50557>
- Viallefont-Robinet, F., & Léger, D. (2010). Improvement of the edge method for on-orbit MTF measurement. *Optics Express*, 18(4), 3531. <https://doi.org/10.1364/OE.18.003531>
- Wagner, W., Sabel, D., Doubkova, M., Bartsch, A., & Pathe, C. (2009). *THE POTENTIAL OF SENTINEL-1 FOR MONITORING SOIL MOISTURE WITH A HIGH SPATIAL RESOLUTION AT GLOBAL SCALE*. 5.
- Walker, J. P., & Houser, P. R. (2004). Requirements of a global near-surface soil moisture satellite mission : Accuracy, repeat time, and spatial resolution. *Advances in Water Resources*, 27(8), 785-801. <https://doi.org/10.1016/j.advwatres.2004.05.006>
- Wan, Z. (2006). MODIS Land Surface Temperature Products. *Institute for Computational Earth System Science, University of California: Santa Barbara, CA, USA*.
- Wang, B., Ono, A., Muramatsu, K., & Fujiwara, N. (1999). *Automated Detection and Removal of Clouds and Their Shadows from Landsat TM Images*. 8.
- Wang, L., Sousa, W. P., Gong, P., & Biging, G. S. (2004). Comparison of IKONOS and QuickBird images for mapping mangrove species on the Caribbean coast of Panama. *Remote Sensing of Environment*, 91(3-4), 432-440. <https://doi.org/10.1016/j.rse.2004.04.005>
- Wenjin Wu, Huadong Guo, Xinwu Li, Ferro-Famil, L., & Lu Zhang. (2015). Urban Land Use Information Extraction Using the Ultrahigh-Resolution Chinese Airborne SAR Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 53(10), 5583-5599. <https://doi.org/10.1109/TGRS.2015.2425658>
- Werbylo, K. L., & Niemann, J. D. (2014). Evaluation of sampling techniques to characterize topographically-dependent variability for soil moisture downscaling. *Journal of Hydrology*, 516, 304-316. <https://doi.org/10.1016/j.jhydrol.2014.01.030>
- Western, A. W., Zhou, S.-L., Grayson, R. B., McMahon, T. A., Blöschl, G., & Wilson, D. J. (2004). Spatial correlation of soil moisture in small catchments and its relationship to dominant spatial hydrological processes. *Journal of Hydrology*, 286(1-4), 113-134. <https://doi.org/10.1016/j.jhydrol.2003.09.014>

- Wiens, J. A. (1989). Spatial Scaling in Ecology. *Functional Ecology*, 3(4), 385.  
<https://doi.org/10.2307/2389612>
- Wigneron, J.-P., Calvet, J.-C., Pellarin, T., Van de Griend, A. A., Berger, M., & Ferrazzoli, P. (2003). Retrieving near-surface soil moisture from microwave radiometric observations : Current status and future plans. *Remote Sensing of Environment*, 85(4), 489-506.  
[https://doi.org/10.1016/S0034-4257\(03\)00051-8](https://doi.org/10.1016/S0034-4257(03)00051-8)
- Wigneron, J.-P., Kerr, Y., Waldteufel, P., Saleh, K., Escorihuela, M.-J., Richaume, P., Ferrazzoli, P., de Rosnay, P., Gurney, R., Calvet, J.-C., Grant, J. P., Guglielmetti, M., Hornbuckle, B., Mätzler, C., Pellarin, T., & Schwank, M. (2007). L-band Microwave Emission of the Biosphere (L-MEB) Model : Description and calibration against experimental data sets over crop fields. *Remote Sensing of Environment*, 107(4), 639-655. <https://doi.org/10.1016/j.rse.2006.10.014>
- Winker, D. M., Pelon, J., Jr, J. A. C., Ackerman, S. A., Charlson, R. J., Colarco, P. R., Flamant, P., Fu, Q., Hoff, R. M., Kittaka, C., Kubar, T. L., Treut, H. L., McCormick, M. P., Mégie, G., Poole, L., Powell, K., Trepte, C., Vaughan, M. A., & Wielicki, B. A. (2010). *A Global 3D View of Aerosols and Clouds*. 20.
- Xie, S., Cheng, Q., Ling, Q., Li, B., Bao, Z., & Fan, P. (2010). Fractal and multifractal analysis of carbonate pore-scale digital images of petroleum reservoirs. *Marine and Petroleum Geology*, 27(2), 476-485. <https://doi.org/10.1016/j.marpetgeo.2009.10.010>
- Yaglom, A. M. (1966). The influence of fluctuations in energy dissipation on the shape of turbulence characteristics in the inertial interval. *Soviet Physics Doklady*, 11, 26.
- Zhan, X., Miller, S., Chauhan, N., Di, L., Ardanuy, P., & Running, S. (2002). *Soil Moisture Visible/Infrared Imager/Radiometer Suite Algorithm Theoretical Basis Document*.
- Zhan, Y., Wang, J., Shi, J., Cheng, G., Yao, L., & Sun, W. (2017). Distinguishing Cloud and Snow in Satellite Images via Deep Convolutional Network. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1785-1789. <https://doi.org/10.1109/LGRS.2017.2735801>
- Zhao, W., & Li, A. (2013). A Downscaling Method for Improving the Spatial Resolution of AMSR-E Derived Soil Moisture Product Based on MSG-SEVIRI Data. *Remote Sensing*, 5(12), 6790-6811. <https://doi.org/10.3390/rs5126790>
- Zhu, Z., Wang, S., & Woodcock, C. E. (2015). Improvement and expansion of the Fmask algorithm : Cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. *Remote Sensing of Environment*, 159, 269-277. <https://doi.org/10.1016/j.rse.2014.12.014>
- Zucker, S. W. (1976). Region growing : Childhood and adolescence. *Computer Graphics and Image Processing*, 5(3), 382-399. [https://doi.org/10.1016/S0146-664X\(76\)80014-7](https://doi.org/10.1016/S0146-664X(76)80014-7)

# Liste des figures

Figure 1.1 : Impact sur l'hétérogénéité des surfaces continentales de facteurs anthropiques tels que les cultures présentes sur l'image de gauche (Arizona, 17 Août 2019, satellite Venus), et de facteurs naturels comme le Delta du Yukon sur l'image de droite (Alaska, 29 Août 2017, satellite Sentinel-2) <a href="https://www.esa.int/ESA_Multimedia">https://www.esa.int/ESA_Multimedia</a> .....	14
Figure 1.2 : Acquisition sur diverses échelles spatiales de l'hétérogénéité des surfaces continentales, au moyen de plusieurs technologies. ....	15
Figure 2.1 : Spectre électromagnétique .....	21
Figure 2.2 : Images acquises dans le visible (composition colorée) en France près d'Agen : à partir d'un avion à gauche, et à partir d'un satellite (SPOT-5) à droite (d'après Pelletier, 2016).....	22
Figure 2.3 : Différentes méthodes d'acquisition du rayonnement électromagnétique pour l'étude des surfaces continentales (d'après Kergomard, 1990).....	24
Figure 2.4 : Images acquises sur le Cambodge : par capteur optique en composition colorée depuis le satellite Sentinel-2 à gauche, et par capteur radar depuis Sentinel-1 à droite. L'emprise de l'image radar inclut celle de l'image optique (pointillés rouges). De plus, la coloration de l'image radar est obtenue en montrant les deux polarisations VV et VH, c'est-à-dire en plaçant dans les canaux RGB de l'image un pourcentage du signal reçu en polarisation verticale (VV) et horizontale (VH) lorsque celui-ci a été initialement émis en position verticale. Les zones de végétation présentant beaucoup de rugosité sont en vert clair, les zones lisses sont en violet (d'après <a href="http://www.pixalytics.com">http://www.pixalytics.com</a> ).....	25
Figure 2.5 : Principe de la classification appliquée aux images satellites (d'après Polidori, 2006). ....	29
Figure 2.6 : Classification à six classes réalisée par SVM à partir de réflectances de surface (d'après Inglada, 2015).....	30
Figure 2.7 : Classification réalisée par Random Forest à partir des réflectances de surface (Landsat-8) acquises le 22/06/2013 sur la ville de Toulouse (d'après Pelletier, 2016).....	31
Figure 2.8 : Segmentation réalisée par croissance de région à partir des réflectances acquises dans une bande spectrale. Les régions détectées sur l'image de droite semblent correspondre aux routes sur l'image originale (d'après Inglada, 2015).....	32
Figure 2.9 : Segmentation réalisée par Mean Shift à partir des réflectances acquises dans le visible (d'après Inglada, 2015).....	33
Figure 2.10 : Présentation schématique du variogramme. Des termes particuliers sont utilisés pour les diverses sections de la courbes : la portée est la gamme des distances $h$ où il y a autocorrélation (pente non nulle), le palier correspond à la variance maximale atteinte pour les grandes échelles de l'image.....	35
Figure 2.11 : Image aérienne de vignes (gauche) ainsi que le module de sa transformée de Fourier (droite). Le pic central correspond aux basses fréquences de l'image, sur lesquelles est répartie la majeure partie de l'énergie. Les pics situés autour du pic central sont directement liés à la présence de vignes dans l'image. La direction formée par ces pics et le pic central correspondent à la perpendiculaire des rangs de vignes, de même que la distance entre un pic et le pic central est associée à la taille des inter-rangs (d'après Delenne et al., 2006).....	36
Figure 2.12 : Phénomènes géophysiques aux propriétés fractales tels que les nuages (gauche) et la topographie (droite). Dans ces deux exemples, chaque partie de l'entité observée présente des propriétés similaires à l'ensemble.....	40
Figure 2.13 : Illustration des concepts de résolution et d'échelle à partir d'une entité fractale à deux dimensions (image satellite). ....	43
Figure 2.14 : Exemple d'objets fractals : (a) ensemble de Cantor de dimension fractale $D_f = 0.63$ et (b) "flocon" de Von Koch avec $D_f = 1.26$ .....	44



Figure 2.15 : Mouvement Brownien fractionnaire unidimensionnel généré avec une intégration fractionnaire d'ordre $H = 0.6$ .....	45
Figure 2.16 : Spectres de puissance estimés à partir d'images satellites (SPOT) et aériennes acquises dans le visible (Laferrière and Gaonac'h, 1999). .....	46
Figure 2.17 : Champ multifractal bidimensionnel généré à partir du modèle des Multifractales Universelles (Schertzer and Lovejoy, 1987), auquel deux niveaux de seuillage $T1$ et $T2$ ont été appliqués tels que $T1 < T2$ .....	49
Figure 2.18 : Allure d'une fonction de codimension dans le cas de champs multifractal ( $c\gamma$ convexe) et monofractal ( $c\gamma = \text{const}$ ) (d'après fig.2.17) .....	49
Figure 2.19 : Schéma de principe d'une cascade multiplicative (d'après Verrier, 2011). .....	51
Figure 2.20 : Passage des cascades à échelles discrètes aux cascades à échelles continues (d'après Schertzer and Lovejoy, 1997). .....	52
Figure 2.21 : Exemples de champs multifractals construits par cascades multiplicatives : (a) cas d'une simulation à échelle discrète via le modèle $\alpha$ , (b) cas continu via le modèle des Multifractales Universelles. L'échelle de couleur est en niveau de gris, avec les faibles valeurs en bleu pour améliorer le contraste (d'après Lovejoy and Schertzer, 2010b). .....	53
Figure 2.22 : Exemple de réalisation bidimensionnelle de la variable aléatoire $\gamma\alpha$ obtenue à partir de la méthode de Chambers et al. (1976). Ici nous avons défini $\alpha = 2$ et $\lambda = 512$ . .....	57
Figure 2.23 : Résultat de la multiplication de $\gamma\alpha$ par le facteur d'amplitude $\sigma$ tel que $C1 = 0.05$ . .....	58
Figure 2.24 : Générateur obtenu après convolution de $\sigma \cdot \gamma\alpha$ et du filtre $g\alpha$ . .....	59
Figure 2.25 : Champ multifractal conservatif. ....	59
Figure 2.26 : Champ multifractal intégré (non-conservatif) obtenu par convolution de $\oplus \lambda$ et du filtre $gH$ . Ici le degré d'intégration fractionnaire a été défini tel que $H = 0.3$ . ....	60
Figure 2.27 : Schéma de principe d'un simulateur de champs multifractals (d'après Verrier, 2011). ..	60
Figure 2.28 : Champs multifractals universels simulés à partir du modèle MU. ....	62
Figure 2.29 : Champ multifractal Rsimu simulé par le modèle MU tel que $\alpha = 2$ , $C1 = 0.05$ , $H = 0.3$ (et $\lambda = 512$ ) .....	63
Figure 2.30 : Représentation log de la Densité Spectrale de Puissance (a) et du Spectre de puissance (b) du champ multifractal Rsimu. Pour la DSP, les basses fréquences spatiales (larges échelles) sont situées au centre de l'image. Dans le cas du spectre de puissance, celles-ci sont situées sur la gauche de l'axe des abscisses. La valeur de l'exposant spectral $\beta$ a été estimée par régression linéaire sur la gamme d'échelles $l$ fit. ....	65
Figure 2.31 : Représentation log des fonctions de structure du champ Rsimu estimées par la méthode des "différences", pour les axes X et Y de l'image. Les larges échelles sont situées sur la partie droite de l'axe des abscisses. Notons que les fenêtres de variations $\Delta x$ et $\Delta y$ sont ici équivalentes (image carrée). ....	67
Figure 2.32 : Dégradation de la résolution d'une cascade multiplicative au moyen d'une succession d'agréments. Ces agréments reviennent à effectuer une moyenne par intervalles disjoints. ....	69
Figure 2.33 : Schéma de principe d'estimation des moments empiriques, de la fonction d'échelle $K(q)$ ainsi que des paramètres $\alpha$ et $C1$ du modèle MU. ....	70
Figure 2.34 : Méthodologie générale pour l'analyse multi-échelle de séries temporelles d'images satellites. ....	72
Figure 3.1 : Effets de l'humidité du sol sur les flux d'eau à l'interface terre-atmosphère (d'après Molero, 2017). ....	75
Figure 3.2 : Echelles d'impact des facteurs environnementaux sur la variabilité spatiale de l'humidité du sol (d'après Peng et al., 2017 ; Crow et al., 2012 ; Jana, 2010). ....	75
Figure 3.3 : Sensibilité des capteurs micro-ondes à l'humidité du sol en bande L (1.4 GHz). La végétation et l'atmosphère ont peu d'effet sur la mesure du signal (Kerr, communication interne). .	77
Figure 3.4 : Schéma de principe de la désagrégation de données spatialisées d'humidité du sol. ....	78



Figure 3.5 : Produits moyens d'humidité du sol acquis par le satellite SMOS (L3 SM) et désagrégés par l'algorithme DisPATCH (L4 disaggregated SM) pour la période 06/2010-05/2011, sur la partie Sud-Est de l'Australie (d'après <a href="#">Molero et al., 2016</a> ).	80
Figure 3.6 : Architecture générale du processeur C4DIS : le pré-processeur DII, le processeur central DisPATCH et le post-processeur DOI (d'après <a href="#">Molero, 2018</a> ).	87
Figure 3.7 : Exemple d'extraction des quatre grilles sous-échantillonnées (lignes en pointillés) à partir de la grille originale SMOS (ligne pleine). Les pixels en gris correspondent aux valeurs à garder et à attribuer à chaque nouvelle grille (d'après <a href="#">Malbêteau et al., 2016</a> ).	90
Figure 3.8 : Schéma de principe de la combinaison des différents produits SMOS et MODIS pour l'obtention d'un produit final d'humidité du sol désagrégée par l'algorithme DisPATCH (d'après <a href="#">Malbêteau et al., 2016</a> ).	91
Figure 3.9 : Schéma de principe de désagrégation de l'humidité du sol par l'algorithme DisPATCH.	93
Figure 3.10 : Zone d'étude située au Sud-Est de l'Australie, incluant les bassins du Murray Darling et du Murrumbidgee (1 million km <sup>2</sup> ).	94
Figure 3.11 : Sous-images sélectionnées pour chaque produit satellite sur le bassin du Murray Darling.	97
Figure 3.12 : Spectres de puissance moyens estimés à partir des produits d'entrée et de sortie de l'algorithme DisPATCH, pour la période Juin-Décembre 2010.	99
Figure 3.13 : Séries temporelles des exposants spectraux sur la période Juin-Décembre 2010 (a) et spectres de puissance obtenus le 9 juillet 2010 (b). $\beta_{large}$ et $\beta_{small}$ font référence aux pentes spectrales de l'humidité désagrégée estimées respectivement pour les échelles $l > 10$ km et $l < 10$ km.	101
Figure 3.14 : Fonctions de structures moyennes des produits DisPATCH estimées selon la méthode des différences, pour la période Juin-Décembre 2010.	103
Figure 3.15 : Moments statistiques moyens et fonctions d'échelle estimés à partir des produits DisPATCH, pour la période Juin-Décembre 2010. Chaque fonction d'échelle est obtenue à partir des régressions linéaires des moments sur les gammes d'échelles correspondantes (deux gammes pour DisPATCH et une gamme pour les autres produits).	105
Figure 3.16 : Résultats obtenus par <a href="#">Kim and Barros (2002b)</a> : spectres de puissance estimés à partir de deux images d'humidité du sol acquises pour un jour humide et un jour sec, durant la mission SGP-97. Nous pouvons observer une rupture de pente vers la dizaine de kilomètres, ainsi qu'une augmentation de cette rupture en conditions plus sèches (courbe pleine).	109
Figure 3.17 : Résultats obtenus par <a href="#">Gires et al. (2011)</a> : spectres moyens des données de précipitations simulées selon le modèle Meso-NH (a) et mesurées par radar (b).	110
Figure 3.18 : Séries temporelles sur la période Juin-Décembre 2010 des anomalies normalisées des trois variables suivantes : la moyenne spatiale de chaque produit d'humidité DisPATCH ; la différence absolue entre les exposants spectraux $\beta_{large}$ et $\beta_{small}$ (estimés respectivement pour $l > 10$ km et $l < 10$ km) ; la position des ruptures d'échelle estimée par segmentation pour chaque spectre. La ligne en pointillés différencie les deux régimes : plutôt humide de juin à septembre et plus sec d'octobre à décembre.	111
Figure 3.19 : Séries temporelles de l'indice de multifractalité $\alpha$ pour la période Juin-Décembre 2010.	112
Figure 3.20 : Campagnes AACES réalisées sur le bassin du Murrumbidgee en septembre 2010 : les mesures aéroportées AACES-2 correspondent aux cinq sections (rectangles en gras) situées sur la moitié centrale de la zone d'étude (d'après <a href="#">Peischl et al., 2012</a> ).	114
Figure 3.21 : (a) Températures de brillances acquises durant la campagne AACES-2. Les pointillés rouges définissent la sous-image extraite pour notre étude. (b) Spectres de puissance des TB ainsi que des différents produits impliqués dans DisPATCH, obtenus sur la période Septembre-Octobre	

2010. Par souci de visualisation et de comparaison, le spectre des TB a été décalé sur la partie basse du graphe (flèche noire).....	115
Figure 3.22 : Comparaison des produits désagrégés d'humidité du sol obtenus après application de notre version simplifiée de DisPATCH (SMHR) et à partir du processeur C4DIS (SM C4DIS), pour le 19 novembre 2010. ....	116
Figure 3.23 : Spectres de puissance des produits d'entrée, intermédiaires et de sortie obtenus à partir de notre implémentation de l'algorithme DisPATCH, pour le 4 Novembre 2010. Le spectre du produit final C4DIS est également tracé ici. Par souci de visualisation et de comparaison, nous avons modifié la position verticale (axe-Y) des différents spectres de puissance.....	117
Figure 3.24 : Images correspondant aux produits Ts, min et SEEHR obtenus d'après notre implémentation de DisPATCH pour le 19 novembre 2010. ....	120
Figure 4.1 : Réflectances de différents types de sol acquises dans le visible - proche infrarouge (d'après <a href="#">Demarez, 2013</a> ). ....	129
Figure 4.2 : Impact de l'absorption par les molécules atmosphériques sur l'éclairement solaire (d'après <a href="#">Kergomard, 1990</a> ).....	136
Figure 4.3 : Impact de l'atmosphère en télédétection optique (d'après <a href="#">Tanré et al., 1986</a> ). ....	137
Figure 4.4 : Schéma récapitulatif des différentes méthodes d'estimation et de détection des composants atmosphériques. ....	139
Figure 4.5 : Région Sud-Ouest correspondant à l'emprise spatiale des quatre tuiles Sentinel-2 (jaune), et comprenant la zone d'étude (rouge) issue de la tuile 30TYP. ....	144
Figure 4.6 : Position spectrale et résolution spatiale des bandes Sentinel-2 <a href="https://www.cesbio.cnrs.fr/la-recherche/activites/missions-spatiales/sentinel-2/">https://www.cesbio.cnrs.fr/la-recherche/activites/missions-spatiales/sentinel-2/</a> .....	145
Figure 4.7 : Chaîne de prétraitement des produits optiques (Niv 1A à 2A). L'image présentée ici correspond à une acquisition faite le 06/06/2006 par le satellite SPOT-5 (d'après <a href="#">Lafrance et al., 2012</a> ). ....	146
Figure 4.8 : Algorithme MAJA.....	149
Figure 4.9 : Image Landsat-8 acquise le 03/04/2013 sur Paris : en composition colorée à partir des bandes "rouge-vert-bleu" à gauche, et dans le canal 1.38 $\mu\text{m}$ à droite (d'après <a href="#">Hagolle et al., 2017</a> ). ....	150
Figure 4.10 : Composition colorée des réflectances TOA acquises dans le bleu, vert et rouge par le satellite Formosat-2, sur le Maroc, le 13/04/2006. Les nuages détectés par la méthode MTCD sont entourés en blancs, et les ombres correspondantes sont entourées en noir (d'après <a href="#">Hagolle et al., 2017</a> ). ....	151
Figure 4.11 : Composition colorée des réflectances TOA acquises par Landsat-8 aux Etats-Unis (gauche), et l'épaisseur optique d'aérosol correspondante estimée par MAJA (droite). Cette épaisseur étant un rapport entre rayonnements incidents et rayonnements affectés par les aérosols, celle-ci s'exprime sans unité (d'après <a href="#">Hagolle et al., 2017</a> ). ....	152
Figure 4.12 : Schéma récapitulatif des différents trajets des rayonnements solaires contribuant à la réflectance TOA mesurée par le capteur satellite (d'après <a href="#">Richter, 2006a</a> ). ....	153
Figure 4.13 : Composition colorée des réflectances TOA (d'après bandes du visible) acquises le 10/07/2016 sur notre zone d'étude (département du Gers – tuile 30TYP).....	154
Figure 4.14 : Chronogramme des acquisitions Sentinel-2A sélectionnées durant la période Janvier-Décembre 2016. ....	155
Figure 4.15 : Spectres de puissance moyens estimés à partir des bandes et indices Sentinel-2, pour la période Janvier-Décembre 2016. ....	157
Figure 4.16 : Fonctions de structure de Haar moyennes estimées à partir des bandes et indices Sentinel-2, pour la période Janvier-Décembre 2016. ....	162

Figure 4.17 : Moments statistiques moyens estimés à partir des bandes et indices Sentinel-2, pour la période Janvier-Décembre 2016. Les droites en rouge et vert correspondent aux régressions linéaires réalisées respectivement sur les gammes I et II. ....	165
Figure 4.18 : Fonctions d'échelle estimées à partir des moments statistiques moyens de la figure 4.17, pour les gammes I (a) et II (b). ....	166
Figure 4.19 : Séries temporelles des exposants spectraux des bandes S2 sur la période Janvier-Décembre 2016, pour les gammes I (a) et II (b). ....	167
Figure 4.20 : Anomalies normalisées obtenues à partir des séries temporelles des paramètres multi-échelles pour les bandes B2 (a), B12 (b) et B8 (c), sur la période Janvier-Décembre 2016 et pour la gamme II seulement. ....	168
Figure 4.21 : Séries temporelles des coefficients de détermination issus des régressions linéaires réalisées sur les spectres des bandes S2, sur la période Janvier-Décembre 2016, pour la gamme II. ....	169
Figure 4.22 : Anomalies normalisées obtenues à partir des séries temporelles des paramètres de qualité multi-échelle ( $R^2$ et $\delta$ ) pour les bandes B8 (a) et B12 (b), sur la période Janvier-Décembre 2016, pour la gamme II. ....	170
Figure 4.23 : Séries temporelles des exposants spectraux obtenus pour le NDVI et les bandes B8/B4 (a), et pour le NSMI et les bandes B11/B12 (b). Ces résultats correspondent à la période Janvier-Décembre 2016, pour la gamme II. ....	171
Figure 4.24 : Séries temporelles des paramètres $C_1$ pour le NDVI et les bandes B8/B4 (a), et pour le NSMI et les bandes B11/B12 (b). Ces résultats correspondent à la période Janvier-Décembre 2016, pour la gamme II. ....	171
Figure 4.25 : Séries temporelles de la position des ruptures large échelle R1 (a) et fine échelle R2 (b) estimées à partir des spectres de puissance des bandes S2, pour la période Janvier-Décembre 2016. ....	174
Figure 4.26 : Six zones d'étude correspondant aux cinq types de surface (cultures, forêt, urbain, vignes, prairies) identifiés à partir de la carte de France d'occupation des sols 2016 du CES OSO. ....	175
Figure 4.27 : Spectres de puissance à la date du 4 février 2016 (a) et séries temporelles de la position des ruptures fine échelle R2 sur la période Janvier-Décembre 2016 (b), pour les bandes du proche infrarouge B8 et B8A. ....	177
Figure 4.28 : Fonction de Transfert de Modulation de la bande B2 estimée et modélisée à partir d'une image S2 acquise sur la ville de Maricopa (Arizona, Etat-Unis). D'après les résultats de <a href="#">Gascon et al. (2017)</a> , pour lesquels la FTM a été obtenue ici suivant la direction des lignes de l'image (Across Track), selon la méthode "slanted-edge" décrite dans <a href="#">Viallefont-Robinet and Léger (2010)</a> . ....	178
Figure 4.29 : Impact de la Fonction de Transfert de Modulation sur les spectres de puissance de champs multifractals simulés. La FTM a été générée à partir du modèle analytique décrit dans <a href="#">Viallefont-Robinet and Léger (2010)</a> . ....	180
Figure 4.30 : Estimation de l'échelle externe $\text{lext}$ de la cascade multiplicative par la méthode macrocanonique appliquée aux moments statistiques: cas d'une image acquise par la bande B8, le 21 octobre 2016. ....	183
Figure 4.31 : Classification des parcelles agricoles en fonction de leur surface estimée selon le Registre Parcellaire Graphique de l'année 2016. Les données représentées ici correspondent à une zone de $\sim 3 \times 3 \text{ km}^2$ extraite dans notre région d'étude globale. Les largeurs de parcelles ont été calculées à partir des aires en approximant celles-ci à des surfaces carré. ....	185
Figure 4.32 : Spectres de puissance des réflectances de surface acquises en été (10 juillet) et automne (21 octobre) 2016 par la bande du proche infrarouge B8. ....	188
Figure 4.33 : Fonctions de structure de Haar estimées à partir des réflectances de surface acquises en été (10 juillet) et automne (21 octobre) 2016 par la bande du proche infrarouge B8. ....	189
Figure 4.34 : Spectres de puissance correspondant aux réflectances des surfaces urban, forests et crops south, acquises en été 2016 par la bande du proche infrarouge B8. ....	191

Figure 4.35 : Données simulées et réelles de réflectances de surface correspondant à la zone d'étude (Gers, tuile 30TYP). La simulation a été obtenue par combinaison d'un champ multifractal et du RPG de l'année 2016.....	192
Figure 4.36 : Estimateurs statistiques et paramètres multi-échelles obtenus à partir des données simulées de réflectances de surface (fig.4.35.a).....	194
Figure 5.1 : Entropie multi-échelle estimée à partir des réflectances Sentinel-2 acquises dans le proche infrarouge, les 4 février, 10 juillet et 21 octobre 2016, sur le département du Gers (tuile 30TYP). Pour chaque courbe, les valeurs maximales d'entropie (flèches noires) sont associées aux échelles de transitions entre les deux régimes. ....	206

# Liste des tableaux



Tableau 2.1 : Récapitulatif des différentes méthodes utilisées en analyse de texture d'images (d'après Humeau-Heurtier et al.,2019).	38
Tableau 2.2 : Présentation des principaux travaux portant sur l'analyse multifractale de l'humidité du sol et des réflectances de surface acquises par télédétection.	41
Tableau 2.3 : Présentation de quelques modèles connus de cascades multiplicatives utilisés en géophysique pour l'étude et la génération de processus multifractals.	54
Tableau 3.1 : Description des principaux capteurs satellites par micro-ondes actives et passives dédiés à l'acquisition de l'humidité du sol.	77
Tableau 3.2 : Description des principales méthodes de désagrégation de l'humidité du sol.	82
Tableau 3.3 : Caractéristiques principales des produits satellites analysés dans cette étude. Sont également précisés la surface au sol, le nombre d'images conservées et le taux moyen de données manquantes (sans les zones hors continent).	98
Tableau 3.4 : Paramètres multi-échelles issus de l'analyse multifractale des produits intervenant dans l'algorithme DisPATCh, pour la période Juin-Décembre 2010. Les valeurs de $\beta$ , $\alpha$ , C1 et H ont été obtenues à partir des régressions linéaires appliquées sur les estimateurs statistiques moyens. En revanche, les coefficients de détermination $R^2$ présentés ici correspondent à la moyenne de l'ensemble des coefficients obtenus pour chaque date. Notons que $RK(q)2$ correspond à la moyenne des coefficients obtenus pour chaque courbe de moments. De même, H est obtenu à partir de la moyenne des paramètres $H_x$ et $H_y$ , ainsi que $RH2$ à partir de $RH_x2$ et $RH_y2$ .	102
Tableau 3.5 : Paramètres $\beta$ obtenus à partir de l'analyse spectrale des produits combinés et générés dans DisPATCh, pour le 19 novembre 2010 (fig.3.23). Les coefficients $R^2$ ont été estimés d'après les régressions linéaires réalisées sur les gammes d'échelles correspondantes. $\Delta\beta = \beta_{large} - \beta_{small}$ est utilisé comme indicateur de l'amplitude de la rupture, avec large et small faisant référence respectivement aux gammes [33 – 9] km et [9 – 1] km.	118
Tableau 4.1 : Description des principaux capteurs optiques dédiés à l'observation de la Terre (VIS = visible, PIR = proche infrarouge, MIR = moyen infrarouge, THERM = infrarouge thermique). Ici les bandes panchromatiques (définies sur une large gamme de longueurs d'onde) ne sont pas prises en compte dans la résolution spatiale du capteur, celle-ci étant généralement supérieure dans ces bandes.	131
Tableau 4.2 : Positions des ruptures d'échelle R1 (et R2 dans le cas des spectres) estimées par segmentation selon D'Errico (2017) pour chaque produit et chaque estimateur statistique moyen.	157
Tableau 4.3 : Paramètres multi-échelles issus de l'analyse multifractale sur les gammes I (a) et II (b) des produits Sentinel-2, pour la période Janvier-Décembre 2016. Les valeurs de $\beta$ , $\alpha$ , C1 et H ont été obtenues à partir des régressions linéaires appliquées sur les estimateurs statistiques moyens. En revanche, les coefficients de détermination $R^2$ présentés ici correspondent à la moyenne de l'ensemble des coefficients obtenus pour chaque date. Notons que $RK(q)2$ correspond à la moyenne des coefficients obtenus pour chaque courbe de moments. De même, H est obtenu à partir de la moyenne des paramètres $H_x$ et $H_y$ , ainsi que $RH2$ à partir de $RH_x2$ et $RH_y2$ .	160
Tableau 4.4 : Positions (en mètres) des ruptures R1 et R2 estimées à partir des spectres de puissance correspondant à six types de surface, observées dans les bandes B2 et B8, en été et en automne 2016.	176
Tableau 4.5 : Comparaison des échelles externes $l_{ext}$ et de rupture $l_{seg}$ (en mètres) estimées respectivement à partir des méthodes macro- et microcanoniques pour les bandes B2 et B8 (21 octobre 2016). Les paramètres universels macro ont été estimés à partir de moments calculés sur la gamme [10 - 160] m, les paramètres micro pour la gamme [10 - 320] m.	184





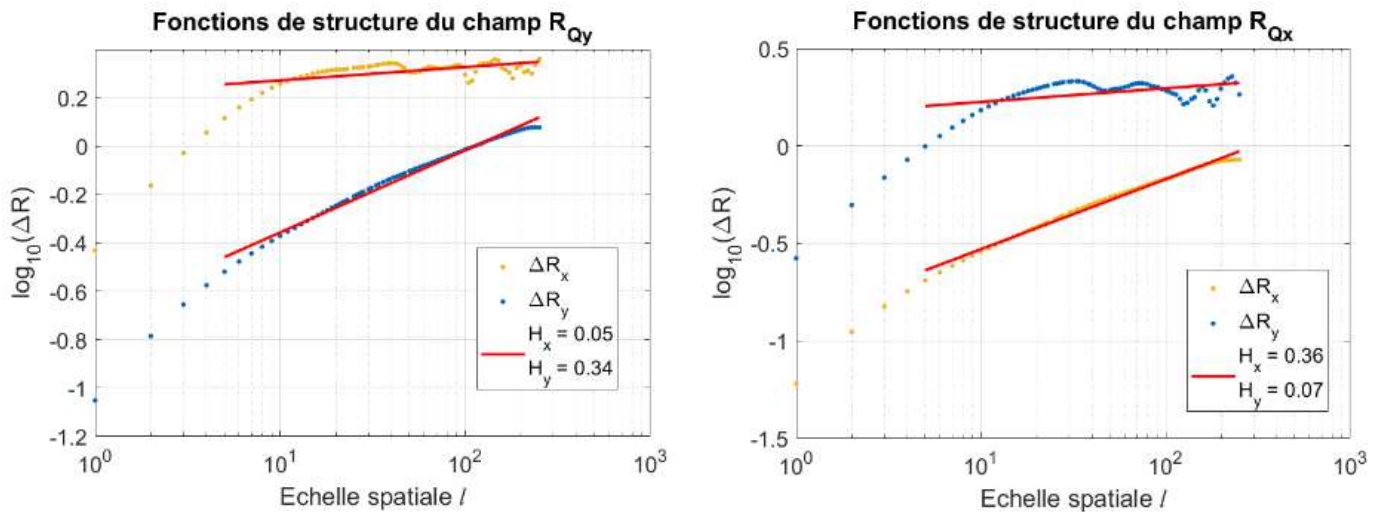
## Annexe A : Simulation de champs multifractals anisotropes

Nous présentons ici des champs anisotropes générés par le modèle auto-affine. Pour cela, nous avons réutilisé les mêmes variables de loi uniforme et exponentielle générées pour la simulation du champ  $R_{simu}$  (cas isotrope, avec les mêmes valeurs de paramètres universels) mais auxquelles deux coefficients de stratification  $Q_x$  et  $Q_y$  ont été appliqués dans l'étape de convolution. Ces coefficients modifient le champ multifractal de tel sorte qu'un zoom d'un facteur  $\lambda$  sur l'axe X de l'image par exemple est équivalent à un zoom d'un facteur  $\lambda^{Q_y}$  sur l'axe Y. Ainsi, nous avons généré deux champs anisotropes :  $R_{Q_y}$  tel que  $Q_x = 0.4$  et  $Q_y = 1$  (zoom sur l'axe des Y) et  $R_{Q_x}$  tel que  $Q_x = 1$  et  $Q_y = 0.4$  (zoom sur l'axe des X).




## Annexe B : Analyse de champs multifractals anisotropes

Nous présentons ci-dessous les fonctions de structure obtenues pour les champs multifractals anisotropes  $R_{Q_y}$  et  $R_{Q_x}$  (Annexe A). Ces fonctions ont été estimées pour les axes X et Y de l'image, et selon la méthode des différences. Pour les deux champs, nous constatons que les valeurs des paramètres  $H_x$  et  $H_y$  sont significativement différentes. Cela confirme donc le caractère anisotrope de ces champs multifractals. De plus, nous pouvons noter que l'axe selon lequel le champ a été étiré (ou zoomé) présente un degré d'intégration fractionnaire  $H$  plus élevé que dans l'autre axe.



En plus des axes X et Y, ces fonctions de structure peuvent être estimées dans différentes directions de l'image. Le graphe polaire ci-dessous présente l'évolution du paramètre  $H$  en fonction de la direction d'estimation de la fonction de structure (angle  $\theta$  par rapport à l'axe Y). Les champs anisotropes  $R_{Q_y}$  et  $R_{Q_x}$  présentent des valeurs de paramètre  $H$  qui augmentent lorsque l'angle  $\theta$  se rapproche de la direction d'étirement du champ (courbes bleue et jaune). A l'inverse, le champ isotrope  $R_{simu}$  présente un paramètre  $H$  plutôt constant selon  $\theta$ .




## Annexe C : Exemple d'application de l'algorithme de segmentation sur le spectre du champ multifractal $R_{simu}$

L'algorithme de segmentation de [D'Errico \(2017\)](#) se présente sous la forme de la fonction Matlab "*slmengine.mat*". Cette fonction nécessite trois paramètres en entrée : la position sur l'axe des abscisses de chaque point du nuage à segmenter (vecteur  $x\_data$ ), la valeur de chaque point sur l'axe des ordonnées (vecteur  $y\_data$ ) et le nombre de ruptures  $nb\_knots$  à détecter. Une fois appliquée, la fonction donne en sortie la position des  $nb\_knots$  ruptures détectées. Notons que le nombre de ruptures est un paramètre qui est donc défini par l'utilisateur. De plus, la fonction détectant toujours en premières ruptures les bornes du nuage de points (valeurs minimale et maximale de  $x\_data$ ), il est donc nécessaire de définir  $nb\_knots \geq 3$  si l'on veut estimer la position d'une rupture située à l'intérieur du nuage de points, que l'on appellera ici "rupture centrale".

A titre d'exemple, nous avons appliqué cette fonction au spectre de puissance obtenu à partir du champ multifractal  $R_{simu}$ . Dans ce cas, nous avons défini les vecteurs  $x_{data} = \log(k)$  et  $y_{data} = \log(E(k))$ . D'après l'allure du spectre, celui-ci semble présenter une seule rupture de pente, soit une seule rupture centrale. De manière à estimer la position cette rupture, nous avons défini ici  $nb\_knots = 3$ . Comme nous pouvons le voir sur la figure ci-dessous, la fonction a effectivement fourni trois positions différentes de rupture. La position centrale qui nous intéresse a été estimée à  $l = 3.5$  (attention axes convertis en log sur la figure).

Afin de vérifier si la position de la rupture centrale est fiable et indépendante du nombre de ruptures proposé par l'utilisateur, nous avons appliqué à nouveau l'algorithme pour des valeurs plus élevées de  $nb\_knots$  (4 puis 5 ruptures). Pour chaque cas, nous estimons une position située à  $l \approx 4$ , ce qui confirme la présence d'une rupture de pente à cette échelle.



Ainsi, nous avons appliqué cette méthodologie aux différents produits satellitaires de cette étude pour identifier les bornes des gammes d'échelles.





Annexe D : Gammes d'échelles utilisées pour l'analyse multifractale des produits DisPATCH

	<b>SPECTRA (km)</b>	<b>STRUCTURES (km)</b>	<b>MOMENTS (km)</b>
<b>SM DISPATCH</b>	[1 – 13] [13 – 1024]	[1 – 7] [7 – 1024]	[1 – 11] [11 – 1024]
<b>SM SMOS</b>	[50 – 1600]	[50 – 1600]	[25 – 400]
<b>LST Aqua-MODIS</b>	[1 – 1024]	[5 – 150]	[8 – 256]
<b>LST Terra-MODIS</b>	[1 – 1024]	[5 – 150]	[8 – 1024]
<b>NDVI Terra-MODIS</b>	[1 – 1024]	[5 – 150]	[8 – 256]



Annexe E : Séries temporelles des paramètres  $H_x$  et  $H_y$  obtenus à partir des produits DisPATCH sur la période Juin-Décembre 2010



Annexe F : Spectres de puissance des produits de Température de  
Brillance AACES-2, pour les deux polarisations H et V



Annexe G : Produits désagrégés d'humidité du sol obtenus le 19 novembre 2010 selon notre *version simplifiée de DisPATCh*.  
 Comparaison des deux cas utilisant en entrée soit une seule image SMOS ou soit quatre images SMOS sous-échantillonnées.













## Annexe H : Gammes d'échelles utilisées pour l'analyse multifractale des produits Sentinel-2


	Grid spacing (m)	SPECTRA		STRUCTURES		MOMENTS	
		<i>Small scales (m)</i>	<i>Large scales (km)</i>	<i>Small scales (m)</i>	<i>Large scales (km)</i>	<i>Small scales (m)</i>	<i>Large scales (km)</i>
<b>B2</b>	10	[40 – 400]	[1 – 41]	[40 – 300]	[1,5 – 20]	[10 – 320]	[1,27 – 41]
<b>B3</b>							
<b>B4</b>							
<b>B8</b>							
<b>NDVI</b>	20	[75 – 400]	[1 – 41]	[40 – 300]	[1,5 – 20]	[20 – 320]	[1,27 – 41]
<b>B11</b>							
<b>B12</b>							
<b>NSMI</b>							

# Annexe I : Séries temporelles des paramètres multi-échelles $\alpha$ , $C_1$ et $H$ obtenus à partir des réflectances Sentinel-2 pour les gammes *large* et *fine échelle* (Janvier-Décembre 2016)









Annexe J : Anomalies normalisées des séries temporelles de coefficients de détermination  $R^2$  obtenus à partir des régressions linéaires sur les différents estimateurs statistiques (spectres, fonctions de structure et moments) correspondant à la bande B2 de Sentinel-2, sur la gamme *fine échelle* (Janvier-Décembre 2016)



**Annexe K : Séries temporelles des paramètres  $H_x$  et  $H_y$  obtenus à partir des indices optiques Sentinel-2 (et bandes correspondantes) pour la gamme *fine échelle* (Janvier-Décembre 2016)**



Annexe L : Modélisation de la Fonction de Transfert de Modulation d'un capteur optique à partir des caractéristiques de la lentille (diffraction) et du détecteur (échantillonnage)

$$FTM = FTM_{diffract} \times FTM_{sampling}$$

$$FTM_{diffract} = \frac{2}{\pi} \left\{ \cos^{-1} \left( \frac{f}{f_c} \right) - \left( \frac{f}{f_c} \right) \sqrt{1 - \left( \frac{f}{f_c} \right)^2} \right\}$$

$$f = \sqrt{f_x^2 + f_y^2}$$

$$f_c = \frac{a}{\lambda D} \text{ (fréquence de coupure)}$$

$a$  : diamètre de la lentille


$\lambda$  : longueur d'onde du rayon

$D$  : distance focale

$$FTM_{sampling} = \text{sinc} \left( \pi \frac{f_x}{f_s} \right) \cdot \text{sinc} \left( \pi \frac{f_y}{f_s} \right)$$

$f_s$  : fréquence d'échantillonnage

Annexe M : Impact de la FTM sur le spectre de puissance d'un champ multifractal – cas d'un champ agrégé à deux fois l'échelle initiale






## Annexe N : Mise en évidence de propriétés anisotropes dans les réflectances Sentinel-2 du proche infrarouge


Afin d'identifier la présence d'anisotropie au sein des réflectances S2, nous avons estimé les fonctions de structure (ici selon la méthode des différences) pour un ensemble de directions de l'image. Nous présentons ci-dessous (à gauche) deux cas de fonctions de structure obtenues pour la bande B8 en été (10/07/16) et en automne (21/10/16), et chaque fois selon les directions  $\theta = 50^\circ$  et  $\theta = 0^\circ$  (angle  $\theta$  par rapport à l'axe horizontal). Pour une même date, nous constatons des courbes similaires à *large échelle* ( $l > 400\text{ m}$ ), mais qui se différencient à *fine échelle* ( $l < 200\text{ m}$ ). Cette différence sur les *finest échelles* semble plus prononcée en automne (décalage des deux courbes vertes) qu'en été.

Pour confirmer ces observations, nous avons estimé sur la gamme  $l_{fit}$  (20 m – 200 m) les valeurs du paramètre  $H_\theta$ , lesquelles sont tracées sur le graphe polaire ci-dessous (indentifiées par les lignes en pointillé). En plus de ces deux directions, nous avons également tracé les valeurs de  $H_\theta$  obtenues pour d'autres directions. Le graphe polaire ci-dessous présente donc l'évolution du paramètre  $H_\theta$  pour une multitude d'angles  $\theta$ , et pour nos deux dates d'acquisition (courbes verte et rouge) des réflectances du proche infrarouge. Nous constatons une variation de  $H_\theta$ , avec des valeurs maximales pour les directions verticale et horizontale de l'image, et des valeurs minimales pour les directions diagonales ( $\theta \approx \pm 50^\circ$ ).



Afin de caractériser cette variation, nous avons estimé l'écart-type  $\sigma_{H_\theta}$  à partir des différentes valeurs de  $H_\theta$ , et ce pour les deux dates étudiées. Nous obtenons  $\sigma_{H_\theta} \approx 0.025$  en été, et  $\sigma_{H_\theta} \approx 0.04$  en automne. Bien que ces écarts-types présentent des valeurs plutôt faibles, nous constatons tout de même que l'écart-type en automne est presque deux fois plus élevé qu'en été. Pour approfondir cette analyse, le travail décrit ici a également été réalisé pour les autres dates de la période d'étude (Janvier-Décembre 2016), et les trois bandes du visible (B2, B3,

B4). Le graphe ci-dessous présente l'évolution temporelle de  $\sigma_{H_\theta}$  pour ces différentes bandes. Par comparaison aux bandes du visible qui présentent des valeurs faibles et relativement constantes de  $\sigma_{H_\theta}$  au cours de l'année, la bande du proche infrarouge révèle une augmentation marquée de  $\sigma_{H_\theta}$  durant la saison d'automne avec un pic positionné à la date du 21/10. Cette dynamique temporelle de  $\sigma_{H_\theta}$  montre d'une part que les propriétés anisotropes observées pour la bande B8 sont effectivement générées par le signal physique mesuré dans le proche infrarouge (et non par des artefacts numériques) et d'autre part que cette anisotropie est directement liée à la structure spatiale des surfaces continentales qui évolue au cours des saisons.



## Annexe O : Application de l'Entropie Multi-échelle pour mettre en évidence les propriétés fractales d'images simulées

Nous présentons ici les résultats obtenus après application de l'entropie multi-échelle (MSE) sur des simulations de champs multifractals. Ces derniers ont été générés pour différentes valeurs de  $H$  comprises entre -0.45 et 1.05, des paramètres universels  $\alpha = 2$  et  $C_1 = 0.5$  et une résolution maximale  $\lambda = 1024$  (images de  $1024 \times 1024$  pixels).

L'entropie multi-échelle a été estimée en appliquant la méthode adaptée au cas 2D, qui est décrite dans [Silva et al. \(2018\)](#). Cette méthode consiste à agréger l'image à différentes échelles (par simple moyenne des pixels voisins), et à estimer pour chacune de ces échelles l'entropie d'échantillon ([Richman and Moorman, 2000](#); [Silva et al., 2016](#)). Afin de limiter le temps de calcul et de fournir les meilleurs performances, l'entropie d'échantillon a été calculée en respectant les mêmes conditions d'implémentation que celles définies par [Silva et al. \(2018\)](#), soit un facteur de tolérance  $r = 0.95$ , une longueur d'échantillons  $m = 2$ , et une échelle maximale d'agrégation  $l_{max} = 20$ .

La figure ci-dessous présente, en coordonnées log-log, les différentes courbes de MSE obtenues pour nos champs simulés. Pour chaque courbe, nous avons estimé les valeurs du paramètre  $H'$  (Eq.5.1) noté ici  $H_e$  et correspondant à la pente obtenue par régression linéaire sur la gamme  $l_{fit}$  (soit pour  $4 < l < l_{max}$ ). Nous constatons que les valeurs de  $H_e$  sont comparables aux valeurs théoriques ( $H_t$ ), avec une loi d'échelle de bonne qualité dans chacun des cas ( $R^2 > 0.9$ ).

