



**HAL**  
open science

## Extraction des zones cohérentes par l'analyse spatio-temporelle d'images de télédétection

Thomas Guyet, Simon Malinowski, Mohand-Cherif Benyounès

► **To cite this version:**

Thomas Guyet, Simon Malinowski, Mohand-Cherif Benyounès. Extraction des zones cohérentes par l'analyse spatio-temporelle d'images de télédétection. Proceedings of the Spatial Analysis and Geography conference (SAGEO), Nov 2014, Grenoble, France. 10.3166/HSP.2014.1-14 . hal-01088643

**HAL Id: hal-01088643**

**<https://inria.hal.science/hal-01088643>**

Submitted on 28 Nov 2014

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

---

# Extraction des zones cohérentes par l'analyse spatio-temporelle d'images de télédétection

Thomas Guyet<sup>1</sup>, Simon Malinowski<sup>2</sup>, Mohand Cherif Benyounés<sup>1</sup>

1. AGROCAMPUS-OUEST/IRISA UMR 6079

65 rue de Saint-Brieuc

35042 Rennes, France

thomas.guyet@agrocampus-ouest.fr

2. FEMTO-ST

32 Avenue de l'Observatoire

25000 Besançon, France

---

**RÉSUMÉ.** Cet article présente une méthode de segmentation de séries temporelles d'images satellite (SITS) en zones cohérentes, c'est-à-dire en des régions géographiques ayant des comportements temporels homogènes. L'objectif de cette méthode est, d'une part, d'extraire des caractéristiques spatio-temporelles d'une région observée et, d'autre part, d'obtenir cette caractérisation de manière efficace en temps de calcul pour traiter de grandes masses de données. Cette méthode est appliquée à la caractérisation des régions agro-écologiques du Sénégal par l'analyse des images MODIS sur un an (23 dates).

**ABSTRACT.** This paper presents a segmentation method of satellite images time series (SITS) in coherent areas, i.e. in geographical regions having homogeneous temporal behavior. The aim of the method is firstly to extract space-time characteristics of an observed region and secondly to obtain this characterization efficiently in terms of computing cost. This method is applied to the characterization of agro-ecological regions of Senegal by the analysis of MODIS images on one year (23 dates).

**MOTS-CLÉS :** Séries temporelles, images satellite, clustering, segmentation

**KEYWORDS:** Time series, satellite images, clustering, segmentation

---

DOI:10.3166/HSP.2014.1-14 © SAGEO Lavoisier

## 1. Introduction

La cartographie de l'occupation du sol consiste à identifier dans une image les régions connexes ayant des propriétés uniformes. Pour améliorer cette cartographie des sols, les agronomes s'intéressent aux séries temporelles d'images satellite (SITS – *Satellite Image Time Series*). Les différents types de végétation ayant des comportements phénologiques différents, l'utilisation de SITS améliore la discrimination des types de végétation par rapport à une analyse d'image satellite mono-date.

Dans le cas de SITS, on cherche à extraire des régions qui caractérisent l'espace par un comportement homogène, c'est-à-dire ayant une dynamique d'évolution dans le temps qui soit similaire. Ce type de région est appelé ici une zone cohérente de l'image. Nous nous intéressons autant à la délimitation des zones cohérentes (aspect spatial) qu'à la caractérisation des dynamiques de végétation qui caractérisent ces zones (aspect temporel). Le manque de connaissance a priori sur nos zones d'étude nous conduit à privilégier des approches non-supervisées.

L'intérêt d'une telle approche est d'améliorer la segmentation des régions de l'espace en étant en mesure de mieux discriminer les différents types de sol. L'objectif n'est donc pas de faire un suivi dans le temps de la végétation, mais bien de caractériser le sol (indépendamment de la date) au travers de sa dynamique de végétation. L'utilisation d'information à plusieurs dates apporte des informations riches pour discriminer les différents types de végétation par leurs cycles phénologiques. De plus, la capacité de résilience de la végétation lors de périodes sèches permet de discriminer les caractéristiques des sols. C'est en tirant profit de ces informations riches qu'il est possible d'améliorer la cartographie des sols à grande échelle.

Le problème de la segmentation de SITS doit néanmoins être abordé en prenant en compte la masse de données à traiter. La fréquence d'acquisition de certains satellites tel que MODIS, permet de disposer d'images de la même région du globe tous les jours à des résolutions spatiales moyennes (environ 250m). Le déploiement en cours de la constellation de satellites du programme Sentinel, qui vise une résolution temporelle d'environ 10 jours et une résolution spatiale d'environ 10m, rendra les méthodes de traitements des SITS de plus en plus intéressantes pour les agronomes. En plus des résolutions des images, il faut aussi considérer la quantité d'information par pixel. Lorsque l'on s'intéresse à la végétation au sol, différents indices peuvent être extraits des bandes spectrales pour quantifier la végétation ou l'eau à la surface des sols : NDVI, EVI, NDII, NDWI. Chacun de ces indices a ses spécificités et leur combinaison aide à discriminer la végétation. Dans le cas général, les SITS sont "multivariées" : chaque localisation est décrite par plusieurs séries temporelles.

La mise au point de méthodes efficaces pour traiter cette grande masse de données est devenue un enjeu important pour aider à la compréhension de l'environnement. Cette problématique peut aujourd'hui être vue sous un nouvel angle grâce aux progrès en traitement d'image satellite qui laisse envisager des traitements à grande échelle spatiale et à haute résolution temporelle. En particulier, l'utilisation de méthodes de segmentation (Blaschke, 2010 ; Weber *et al.*, 2012) a montré des résultats prometteurs

pour l'analyse d'images à haute résolution spatiale. Cependant, l'extension de ces méthodes aux SITS afin d'exploiter à la fois les informations spatiales et temporelles contenues dans ces données reste à explorer et à éprouver dans le cadre de l'extraction de zones cohérentes.

L'objectif de cet article est de présenter une méthode efficace, à la fois en termes de temps de calcul et de performance en cartographie du sol, de segmentation de régions de l'espace en zones cohérentes. Cette méthode non-supervisée extrait une caractérisation des zones cohérentes par des informations sur les évolutions moyennes des indices suivis (NDVI et EVI). La méthode est appliquée à la cartographie des zones agro-écologiques du Sénégal. Nous montrons que l'efficacité de notre méthode permet de traiter de grandes images avec des résolutions temporelles importantes avec des temps de traitement réduits, et que les caractérisations sont utiles à la compréhension de l'occupation du sol.

## 2. État de l'art

Parmi les méthodes d'analyse d'image satellite qui cherchent à prendre en compte des images acquises à plusieurs dates, on trouve principalement des méthodes qui traitent les images pixel à pixel en prenant en compte le temps soit par des analyses bi-temporelles soit par des méthodes basées sur les séries temporelles. L'analyse bi-temporelle étudie des transitions et des changements brusques qui se produisent entre deux observations, par exemple, par des différences pixel à pixel entre deux images (Bruzzone, Prieto, 2000). Petitjean *et al.* (Petitjean *et al.*, 2010) utilisent des motifs séquentiels pour caractériser des changements sur plusieurs dates et plusieurs bandes. D'un autre côté, de nombreuses méthodes visent à exploiter les séries temporelles portées par les pixels d'une SITS. Un des problèmes des données satellite est la régularité des acquisitions. Du fait des couvertures nuageuses et de la disponibilité des images, les séries temporelles sont non-régulières et comportent beaucoup de données manquantes. L'adaptation de la *Dynamic Time Warping* pour la classification de séries temporelles élimine ces contraintes (Petitjean, Inglada, Gancarski, 2012). Lorsque les séries temporelles sont acquises sur de longues durées, la méthode BFAST (Verbesselt *et al.*, 2010) effectue une analyse des tendances et des saisonnalités dans les pixels des SITS. Pour traiter des SITS régulières de longue durée, *i.e.* plusieurs années à raison d'une image tous les 16 jours, Guyet *et al.* (Guyet *et al.*, 2012) proposent une approche de segmentation temporelle multi-échelles.

Les méthodes de traitement pixel à pixel utilisent l'information temporelle, mais ne tiennent pas compte de l'information spatiale, en particulier du voisinage d'un pixel lors de ce traitement. Les méthodes suivantes ont été proposées pour répondre à cet objectif. La méthode de Petitjean (Petitjean, Kurtz *et al.*, 2012) fournit à la fois une analyse temporelle et spatiale d'images à haute résolution spatiale pour la caractérisation de terre agricole. La méthode comporte 5 grandes étapes : segmentation des images, caractérisation des régions, construction des vecteurs d'images, construction et classification des séries temporelles. Dans un premier temps, chaque image de la

SITS est segmentée. Ces segmentations enrichissent, à un instant  $t$ , chaque pixel avec des attributs spatiaux calculés sur le segment d'appartenance du pixel. Un pixel de l'image est ensuite caractérisé par une série temporelle multivariée, où les dimensions combinent les valeurs spectrales des pixels et les valeurs spatiales des régions d'appartenance. Une classification supervisée de ces représentations pixels est construite pour extraire des caractéristiques des SITS prenant en compte des informations sur le voisinage des pixels. Cette approche met l'accent sur l'aspect spatial en identifiant les segments homogènes à un instant  $t$ , mais l'aspect temporel n'est développé que lors de la classification des séries temporelles de chaque pixel. Les temps de calcul et l'usage mémoire permettent le traitement des données de faible taille.

Julea *et al.* (Julea *et al.*, 2011) ont cherché à utiliser des motifs séquentiels fréquents dans un contexte spatio-temporel. Pour cela, des ensembles de pixels connectés et partageant une évolution temporelle similaire sont extraits. Ils montrent qu'une contrainte de voisinage entre pixels, combinée à un seuil de similarité, peut être partiellement exploitée afin d'élaguer l'espace de recherche. En collaboration avec une contrainte de maximalité simple, la méthode révèle des tendances significatives. L'une des difficultés importante de ce travail est de quantifier l'information (spectrale ou sous forme d'indice) pour construire des motifs. De plus l'information temporelle n'est extraite que sous forme de séquences.

Weber *et al.* (Weber *et al.*, 2012) proposent une approche d'analyse des SITS qui visent à améliorer les temps de calcul pour des traitements sur des données massives. La problématique est donc très similaire à celle à laquelle nous nous intéressons. Les auteurs proposent de combiner la méthode de segmentation spatio-temporelle des zones quasi-plates (ZQP) (Weber, Lefèvre, 2013), utilisée en traitement vidéo, avec une classification des SITS par une DTW. Cette approche réduit à la fois le temps et la consommation de mémoire. Néanmoins, l'algorithme ZQP n'est pas adapté aux images comportant beaucoup de couches de données, comme le sont les SITS multivariées. Pour cette raison, nous proposons une méthode alternative, basée sur la segmentation orientée objet, capable de segmenter une image en utilisant des caractérisations sous la forme de séries temporelles multivariées.

### 3. Présentation de la méthode

De même que pour Weber *et al.* (Weber *et al.*, 2012), nous associons une méthode de classification de séries temporelles avec une méthode de segmentation pour exploiter les deux dimensions spatiales et temporelles dans les SITS. Les séries temporelles que nous traitons ici sont multivariées. Nous nous limitons à des distances euclidiennes entre les séries temporelles même si les adaptations existantes des DTW (Petitjean, Inglada, Gancarski, 2012) pourraient remplacer cette distance. Pour la méthode de segmentation, nous avons choisi une méthode dite de *segmentation orientée objet* (Blaschke, 2010). Les méthodes orientées objet sont très appropriées pour l'analyse d'images à haute résolution spatiale mais l'extension de ces méthodes à des données temporelles n'a pas été traitée dans la littérature. Dans le cas des images satel-

lites, nous parlons d'un objet pour désigner un ensemble de pixels connexes avec des comportements dans le temps "similaires". La méthode de segmentation de la section 3.1 précisera la notion de similarité entre pixels.

La méthode proposée est basée sur le déroulement suivant (voir figure 1 pour les résultats intermédiaires) :

1. Segmentation de la SITS et construction des caractéristiques des objets;
2. Catégorisation des objets;
3. Construction des zones cohérentes;

Les différentes étapes du traitement sont détaillées dans les sections suivantes.

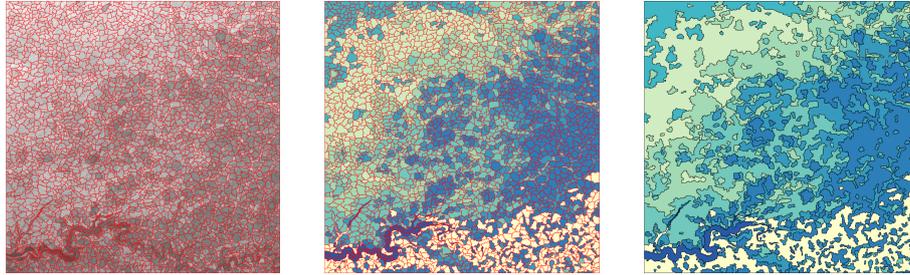


Figure 1. Étapes de la construction des zones cohérentes. À gauche, résultat de la segmentation, au milieu, résultat de la catégorisation des segments et, à droite, résultat de la fusion en zones cohérentes.

### 3.1. Segmentation objet de la SITS

Considérons une SITS  $\mathcal{S} = \langle \mathcal{I}_t \rangle_{t=1..n}$  de  $n$  dates, de hauteur  $H$  et de largeur  $W$ . On note  $E = [1..H] \times [1..W]$  l'ensemble des pixels de l'image. Pour chaque date  $t$ , une image est composée de  $\beta$  variables (*e.g.* NDVI ou EVI). On a donc  $\forall (x, y) \in E, \mathcal{I}_t(x, y) \in [0, 1]^\beta$ , les variables étant préalablement normalisées.

La première étape consiste à segmenter  $\mathcal{S}$  en segments homogènes, ou *objets*, qui vont constituer une partition de  $E$ . Un "objet" correspond à une région de l'espace décrite par des caractéristiques de forme (sa surface, la longueur de son contour) et par des caractéristiques spectrales. Dans le cas de SITS, les caractéristiques spectrales comportent une dimension temporelle. Nous utilisons les séries temporelles moyennes et les séries temporelles des écarts-types de chacune des variables de l'image.

L'algorithme de segmentation est illustré par le pseudo code ci-dessous. Initialement, chaque pixel correspond à un objet. Le principe général est de fusionner progressivement les objets par paire d'objets voisins "homogènes" tant que les objets n'atteignent pas une taille critique. Chaque objet  $o$  est traité séquentiellement<sup>1</sup> et une

1. On peut noter que l'ordre dans lequel son parcourus les objets à de l'importance sur le résultat.

mesure d'homogénéité de la fusion de  $o$  avec chacun de ses voisins  $no$  est calculée. Lorsqu'un objet a plusieurs voisins potentiels avec qui fusionner ( $h_{diff}(o, no) < s^2$ ), alors il est fusionné avec celui qui donnera l'hétérogénéité la moins importante.

---

**Algorithm 1** Méthode de segmentation orientée objet
 

---

```

1: for  $(x, y) \in E$  do                                     ▷ Chaque pixel est un objet
2:    $o \leftarrow (x, y)$ 
3:    $\mathcal{O}.append(o)$ 
4: end for
5:  $fusiondone \leftarrow true$ 
6: while  $fusiondone$  do                                   ▷ Tant que des fusions sont faites, on continue à fusionner
7:    $fusiondone \leftarrow false$ 
8:   for  $o \in \mathcal{O}$  do                                     ▷ Pour chaque objet
9:      $o_{min} = \emptyset, \quad min \leftarrow \infty$ 
10:    for  $no$ , objet voisin de  $o$  do
11:       $h \leftarrow h_{diff}(o, no)$                        ▷ Calcul de la mesure d'intérêt de la fusion entre objets
12:      if  $h < s^2$  et  $h < min$  then
13:         $min \leftarrow h, \quad o_{min} \leftarrow no$ 
14:         $fusiondone = true$ 
15:      end if
16:    end for
17:    if  $min < \infty$  then                               ▷ On fusionne les objets  $o$  et  $o_{min}$ 
18:       $\mathcal{O}.append(merge(o, o_{min}))$ 
19:       $\mathcal{O}.remove(o), \quad \mathcal{O}.remove(o_{min})$ 
20:    end if
21:  end for
22: end while

```

---

L'algorithme de segmentation est fondé, d'une part, sur un paramètre d'échelle  $s$  qui limite la taille des objets et, d'autre part, sur la définition d'homogénéité d'objets voisins. On détaille maintenant ce second point en présentant le calcul de  $h_{diff}$ .

Soit  $o \in \mathcal{O}$  (ensemble des objets) un objet correspondant aux pixels  $\mathcal{S}(o) \subset E$ .  $\mathcal{S}(o)$  peut être vu comme un masque binaire localisant les pixels de l'image qui compose  $o$ . On note  $|\mathcal{S}(o)|$  la surface de l'objet. Soit  $b \in [1, \beta]$  une variable de l'image, on note alors  $\mu_b(o)$  la série temporelle de longueur  $n$  composée des moyennes des valeurs spectrales de la variable  $b$  dans  $\mathcal{S}(o)$ , et  $\sigma_b(o)$  la série temporelle correspondant aux écart-types des valeurs de la variable  $b$  dans  $\mathcal{S}(o)$ .

Dans l'algorithme de segmentation, deux objets  $o_1$  et  $o_2$  peuvent être fusionnés en un objet  $o$  si  $h_{diff}(o) < s^2$ , où

$$h_{diff} = \sum_{b=1..\beta} h_{diff}(b), \text{ et}$$

$$h_{diff}(b) = \sum_{t=1..n} |\mathcal{S}(o)| \times \sigma_b(o)(t) - (|\mathcal{S}(o_1)| \times \sigma_b(o_1)(t) + |\mathcal{S}(o_2)| \times \sigma_b(o_2)(t))$$

Ce critère simple indique que deux objets connexes sont donc considérés comme homogènes si la différence de la variance de l'ensemble avec la somme des variances de deux régions est inférieure à  $s^2$ . Il est également possible de contraindre la forme des objets (par leur rapport surface sur longueur de contour).

À l'issue de la segmentation, on obtient un ensemble d'objets  $\mathcal{O}$  tel que l'illustre la Figure 1 (à gauche) où les lignes rouges délimitent les différents objets. Pour chaque objet  $o$ , on conserve les valeurs moyennes de chacune des variables  $(\mu_b(o))_{b \in [1..\beta]}$  comme caractéristique de l'objet. Ces caractéristiques servent à catégoriser les objets dans l'étape suivante.

### 3.2. Catégorisation des objets

L'objectif de la catégorisation est de construire des classes  $\mathcal{C} = (c_i)_{i=1..k}$  de séries temporelles multivariées (les objets de  $\mathcal{O}$ ). On peut noter que dans cette étape de la méthode, on ne s'intéresse qu'à des séries temporelles sans prendre en compte d'aspect spatial des données.

La distance entre séries temporelles que l'on utilise est la distance euclidienne. Cette distance met en évidence les dates de début de changement de la végétation. Une telle distance est donc plus appropriée qu'une distance élastique telle que la DTW. Elle rend possible l'utilisation de différents algorithmes de catégorisation (*e.g.* K-Means, EM, Affinity Propagation).

À l'issue de l'étape de catégorisation, chaque objet  $o$  appartient à une classe  $c(o) \in \mathcal{C}$ . La Figure 1, au milieu, illustre l'appartenance d'un objet à une classe par sa couleur. Les objets sont toujours délimités par les lignes rouges. En parallèle de cette image, on peut caractériser chacune des classes par un profil d'évolution, *i.e.* une série temporelle multivariée. Ce profil d'évolution est obtenu en faisant la moyenne des caractéristiques des objets d'une classe. Il permet d'analyser les caractéristiques des classes.

### 3.3. Construction des zones cohérentes

Une "zone cohérente" est définie comme un ensemble d'objets contiguës qui appartiennent à la même classe. Ces zones sont construites par fusion des objets connexes qui ont la même classe d'appartenance. Chacune de ces régions est caractérisée par le profil d'évolution de la classe.

La Figure 1 à droite illustre le résultat final de la méthode. Chaque zone cohérente est délimitée par un contour en noir et sa couleur indique sa classe d'appartenance.

## 4. Expérimentations et résultats

Nous présentons maintenant les résultats obtenus pour l'analyse des zones agro-écologiques du Sénégal. Dans une première partie, nous nous sommes attaché à ana-

lyser la méthode par ses performances calculatoires et par l'influence des deux paramètres de la méthode :  $s$  lié aux tailles des objets et  $k$  pour le nombre de catégories. Dans un second temps, nous nous sommes intéressés aux résultats obtenus sur la caractérisation de la végétation du Sénégal.

L'ensemble des algorithmes a été implémenté en C++<sup>2</sup> et l'exécution a été faite sur un ordinateur standard.

#### **4.1. Problématique applicative et données**

Pour cette étude, nous nous intéressons à la caractérisation des zones écologiques du Sénégal. Le Sénégal se situe dans une zone de transition entre la forêt tropicale au sud et les zones arides au nord. La partie centrale du pays regroupe les territoires agricoles du bassin arachidier où l'agriculture pluviale y domine. Cette partie centrale de grande importance socio-économique est particulièrement sensible aux aléas climatiques, accentués par les changements climatiques globaux. Une caractérisation des différentes zones écologiques du Sénégal doit faciliter la gestion des épisodes de sécheresse tel que rencontré en 2002.

Les images proviennent du satellite MODIS (Moderate Resolution Imaging Spectroradiometer). Elles sont librement disponibles de 2001 à aujourd'hui, ce qui rend leur usage très populaire, en particulier pour répondre à des questions environnementales dans les pays en voie de développement. La résolution est d'environ 250m, à l'échelle du Sénégal les images ont une taille d'environ  $4800 \times 4800$  pixels. L'intérêt du programme MODIS est sa fréquence d'acquisition : deux satellites produisent une couverture quotidienne de la surface terrestre. Nous utilisons des images d'indices NDVI<sup>3</sup> et EVI<sup>4</sup> pour des périodes de 16 jours. Cet intervalle est à la fois assez étendu pour obtenir des images de qualité (*i.e.* avec un taux de couverture nuageuse inférieur à 10% sur chaque image) et assez réduit pour ne pas perdre en qualité des séries temporelles.

Nous traitons les images par année, soit des images de 46 bandes : 23 dates avec 2 variables par date ( $n = 23$  et  $\beta = 2$  avec nos notations).

#### **4.2. Analyse de la méthode**

##### **4.2.1. Influence des paramètres $k$ et $s$**

Les images de la figure 2 illustrent les résultats obtenus pour différentes valeurs des paramètres  $k$  et  $s$ . On constate en particulier que lorsque le paramètre d'échelle augmente (modification des images vers le bas), les zones extraites sont de plus en plus grandes et imprécises. Pour les images avec le paramètre d'échelle  $s = 2$ , les

---

2. Les implémentations peuvent être mises à disposition sur simple demande adressée au premier auteur.

3. NDVI: Normalized Difference Vegetation Index

4. EVI: Enhanced Vegetation Index

images sont pixelisées dans les régions de fort changements spatiaux de la végétation (autour du fleuve Gambi). À l'inverse, pour des paramètres d'échelles plus importants et tant que le paramètre  $k$  n'est pas trop faible, cet effet de pixelisation est supprimé tout en conservant une distinction des différentes zones. L'image ne laisse apparaître que les variations de grande échelle spatiale, principalement à la latitude.

Le paramètre  $k$  agit à la fois sur les types de zones différentes qui sont extraites, mais également sur la taille des zones extraites. Pour des valeurs de  $k$  faible, comme il y a moins de variabilité de classe, notamment entre voisins, il y a plus de fusion des régions segmentées lors de la construction des zones cohérentes. Les zones cohérentes sont donc plus grandes.

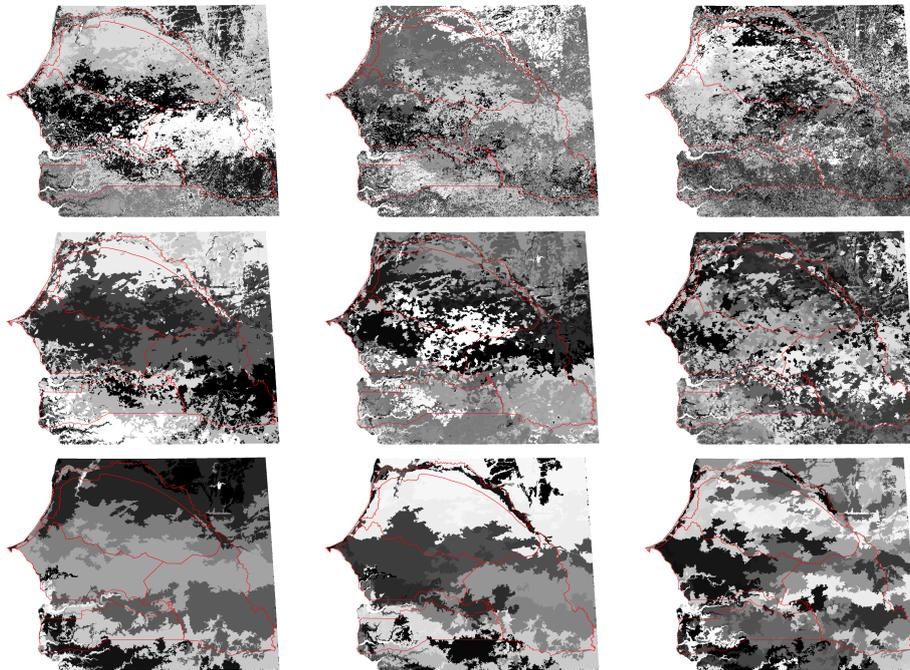


Figure 2. Résultat du traitement pour  $k = 15$  à gauche,  $30$  au milieu et  $k = 80$  à droite, avec un paramètre d'échelle  $s$  valant, de bas en haut :  $2$ ,  $10$  et  $40$ . Les traits rouges délimitent les zones agro-écologiques (ZAE) du Sénégal.

La surface moyenne des zones cohérentes en fonction de  $s$  est proportionnelle à  $k \times \sqrt{s}$  (cf. figure 3). En parallèle des moyennes de taille, nous avons également regardé les valeurs minimales et maximales des tailles. Nous avons constaté, d'une part, que la taille minimale des zones cohérentes est uniquement dépendante de  $s$  et que la taille maximale est quasiment uniquement dépendante de  $k$ . Ces comportements semblent tout à fait cohérents avec notre méthode. D'une part, la segmentation étant réalisée avant la construction des zones cohérentes, la taille des segments minimaux est dépendante de cette segmentation. D'autre part, la valeur de  $k$  majore la possibilité

de fusion en zones cohérentes, et donc la taille maximale de celle-ci, indépendamment des éléments initiaux à fusionner.

Néanmoins, le paramètre d'échelle imposant une contrainte forte sur la taille minimale des zones, on aurait pu penser que la fusion en zones cohérentes engendre des régions de tailles plus variables. L'analyse de la variance des tailles montre que, même avec un  $s$  important la variance est également grande et délimite aussi bien des régions très spécifiques et de petite taille que des grandes régions. Cela s'explique principalement par le fait que même avec un  $k$  important, les zones homogènes agrègent beaucoup d'objets.

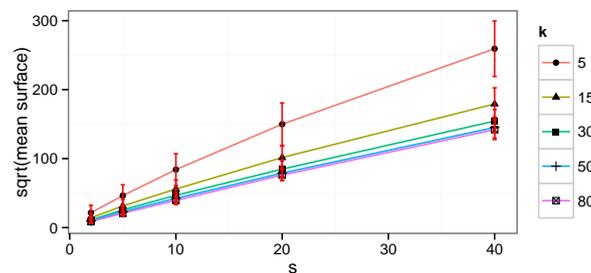


Figure 3. Surface moyenne des zones cohérentes en fonction de  $s$ . La courbe illustre la racine carrée de la surface en nombre de pixels.

#### 4.2.2. Performance en temps et mémoire

De même que pour les zones quasi-plates (Weber *et al.*, 2012), l'objectif d'une classification orientée objet est de sur-segmenter une image pour réduire la taille des données à classer en limitant la perte d'information. Pour être intéressants, les objets de l'image doivent être significativement plus grands que le pixel. Selon les paramètres adoptés, l'utilisation d'objets réduit considérablement le temps de la catégorisation et donne plus de sens à chacun de ces objets.

La figure 4 illustre les temps de calcul. La valeur de  $k$  influence peu les temps de calcul, le paramètre  $s$  est le facteur principal. Les temps décroissent exponentiellement en fonction de  $s$ . Pour les  $s$  petits, le nombre d'objets à catégoriser est plus important et influe donc sur les temps de calcul, l'augmentation des temps de calcul est principalement due au temps de la segmentation. De même, une mémoire importante est nécessaire pour segmenter de grandes images. En pratique, le processus requiert environ 4Go de mémoire pour segmenter l'image à 2 variables et 23 dates. Cette taille requise est linéaire avec le nombre de variables et de dates. Une fois l'image segmentée, la classification ne requiert que très peu de mémoire.

En comparaison avec une méthode de classification des pixels (figure 4 à droite), l'utilisation d'une segmentation objet, même avec des paramètres d'échelles faibles  $s = 2$  ou  $5$ , réduit les temps de calcul d'un ordre de grandeur. Pour comparaison, la méthode des zones quasi-plates a été implémentée, mais ses difficultés à traiter

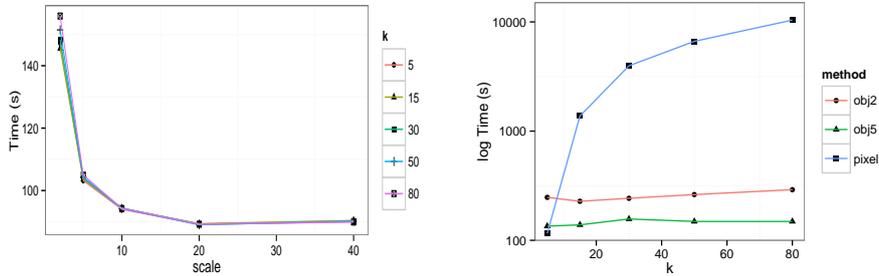


Figure 4. Temps de calcul, à gauche, en fonction de  $s$  et, à droite, en fonction de  $k$  pour  $s = 2$  (obj2) ou 5 (obj5) et pour catégorisation des pixels (échelle logarithmique).

des données comportant un grand nombre de bandes rend les temps de calcul trop importants pour traiter nos images.

### 4.3. Caractérisation des zones agro-écologiques du Sénégal

Le Sénégal est organisé en 6 zones agro-écologiques (ZAE) : le Bassin Arachidier (zone occidentale de latitude médiane), la Casamance (au sud-ouest), la zone du Niayes (pointe ouest), la zones Sylvo-Pastorale (grande zone au nord du pays), le Sénégal oriental (au sud-est) et la Vallée (au nord). Chacune de ces zones dispose d'une végétation spécifique.

L'objectif de cette section est de mettre en évidence que la classification de l'image permet de retrouver les zones agro-écologiques connues.

Pour différentes valeurs de paramètres, on a calculé la matrice de contingence croisant les  $k$  classes avec les 6 ZAE. Chaque ZAE est donc décrite par une distribution des  $k$ -classes. Dans l'idéal, tous les pixels d'une des  $k$ -classes n'appartiennent qu'à une seule et même ZAE. Dans le cas général, il faut que les distributions des  $k$ -classes entre les ZAE soient "différentes". Pour cela, on analyse ces distributions en s'intéressant à la divergence de Kullbach-Lieber (KL) entre les distributions des classes entre des paires de ZAE. Plus cette mesure est proche de 0 et plus les distributions sont proches. La segmentation caractérisera donc d'autant mieux les ZAE que la distance sera importante.

La figure 5 donne la moyenne de KL en fonction de  $s$  pour différentes valeurs de  $k$ . La moyenne est pondérée par le nombre de pixels de chaque classe. Les valeurs intéressantes de ce graphe sont les valeurs de KL importantes avec des paramètres d'échelle qui soit grands. Ceci correspondant aux adéquations les plus discriminantes du point de vue des ZAE et pour lesquelles les régions sont les plus grandes, *i.e.* mieux réduites par la segmentation. On constate que globalement la distance KL décroît avec le paramètre d'échelle pour un même nombre de classe, et que ce taux de décroissance

diminue avec le nombre de classes. Pour  $k = 80$ , la décroissance est importante tandis que pour  $k = 15$  cette décroissance est plus faible. Les valeurs de paramètre  $k = 30$ ,  $s = 40$  ou  $k = 15$ ,  $s = 20$  donnent les meilleurs compromis entre taille des régions et discrimination des classes.

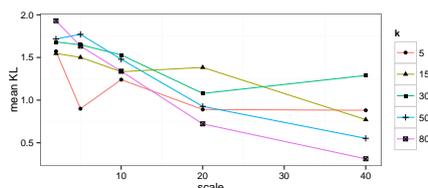


Figure 5. Distance moyenne de Kullback-Liebert entre paires de distributions de classes entre les zones agroécologiques en fonction de  $s$ .

#### 4.4. Analyse des séries temporelles multi-variées

Les 6 zones agro-écologiques du Sénégal disposent chacune d'une végétation spécifique. La figure 6 illustre 6 profils annuels caractéristiques qui sont extraits automatiquement pour  $k = 15$  et  $s = 10$ . Chaque classe est représentée par des profils pour le NDVI et l'EVI. Plus les indices NDVI et EVI sont importants et plus la couverture végétale est importante. Nous avons sélectionné les classes les plus spécifiques de chaque ZAE. La classe 8 correspond à la Casamance dont la végétation est constituée principalement de forêts. Les profils annuels montrent une végétation importante plus durable que la végétation des classes 2 et 9 correspondant à la ZAE orientale sud. Ces deux classes se distinguent par leur date de début de végétation, plus précoce au sud (classe 9). La classe 2 capte les comportements des forêts du bassin Arachidier. La classe 15 correspond au sud de la région de la Casamance composée principalement de forêts équatoriales denses, son niveau de végétation est haut et quasiment constant. À l'opposé, les classes 7 et 10 sont les classes du nord du Sénégal, plus sec. Pour ces classes, il y a peu de correspondance avec les ZAE. Les profils se distinguent par la quantité de végétation en période humide. La classe 7 correspond au nord du pays, zone plus sèche que les zones de latitude médianes de la classe 10. Les zones délimitent ainsi des régions partiellement cultivées, et des régions sèches, peu propices au développement de l'agriculture.

## 5. Conclusion

Nous avons proposé une méthode pour segmenter des SITS s'appuyant sur la caractérisation des comportements dynamiques des sols. Nous avons appliqué cette méthode à la segmentation des zones agro-écologiques du Sénégal sur une année et étudié l'influence de ses deux paramètres sur les tailles moyennes des régions segmentées.

En adaptant la méthode de segmentation objet, l'algorithme améliore le temps de catégorisation d'un ordre de grandeur par rapport à une catégorisation par pixel.

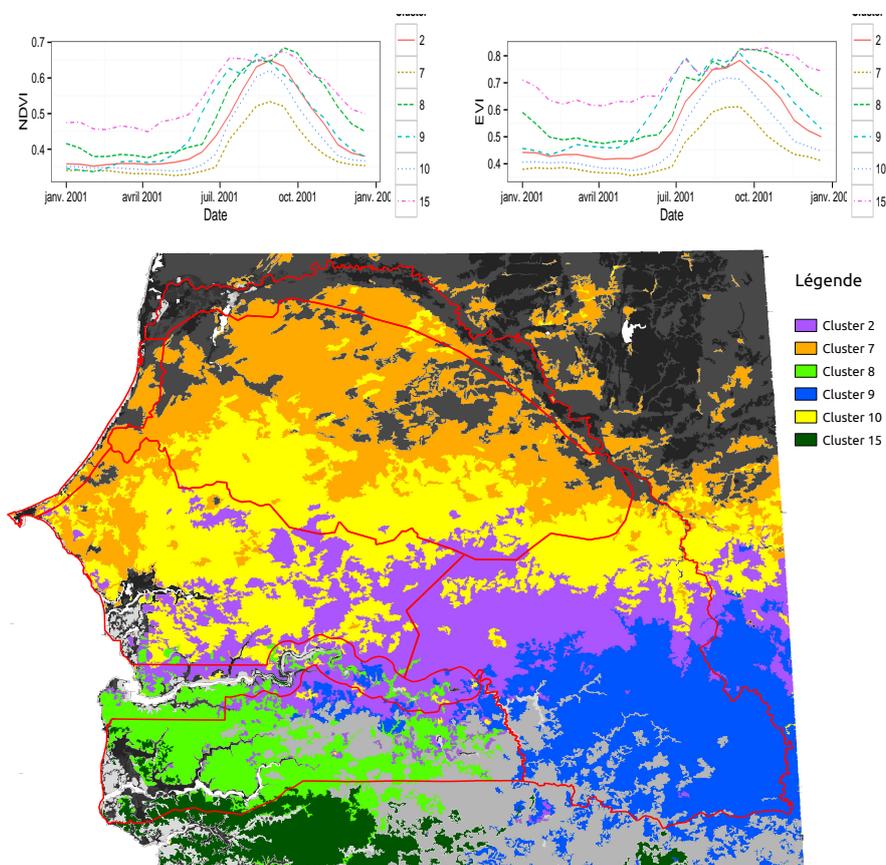


Figure 6. Caractérisation et localisation des classes extraites principales.

La méthode se montre intéressante pour extraire des caractéristiques spécifiques aux différentes ZAE. La méthode proposant en même temps des caractérisations de régions plus fine, ces petites structures sont à analyser dans la suite de nos travaux. Nous souhaitons également poursuivre ce travail en montrant le pouvoir discriminant des caractérisations qui ont été extraites.

### Bibliographie

- Blaschke T. (2010). Object based image analysis for remote sensing. *J. Photogramm.*, vol. 65, n° 1, p. 2–16.
- Bruzzone L., Prieto D. (2000). Automatic analysis of the difference image for unsupervised change detection. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, n° 3, p. 1171–1182.

- Guyet T., Nicolas H., Diouck A. (2012). Segmentation multi-échelle de séries temporelles d'images satellite : Application à l'étude d'une période de sécheresse au Sénégal. In *Actes de la conférence RFIA 2012*, p. 6.
- Julea A., Méger N., Rigotti C., Trouvé E., Bolon P., Lazarescu V. (2011). Mining pixel evolutions in satellite image time series for agricultural monitoring. In *Advances in data mining. applications and theoretical aspects*, vol. 6870, p. 189–203.
- Petitjean F., Gañçarski P., Maseglia F. (2010). Extraction de motifs d'évolution dans les séries temporelles d'images satellites. In *Spatial analysis and geomatics*.
- Petitjean F., Inglada J., Gancarski P. (2012). Satellite image time series analysis under time warping. *IEEE Transactions on Geoscience and Remote Sens.*, vol. 50, n° 8, p. 3081–3095.
- Petitjean F., Kurtz C., Passat N., Gañçarski P. (2012). Spatio-temporal reasoning for the classification of satellite image time series. *Pattern Recognition Letters*, vol. 33, n° 13, p. 1805–1815.
- Verbesselt J., Hyndman R., Newnham G., Culvenor D. (2010). Detecting trend and seasonal changes in satellite image time series. *Remote Sens. Environ.*, vol. 114, n° 1, p. 106–115.
- Weber J., Lefèvre S. (2013). Fast quasi-flat zones filtering using area threshold and region merging. *J. of Vis. Com. and Image Repr.*, vol. 24, n° 3, p. 397–409.
- Weber J., Petitjean F., Gañçarski P. (2012). Towards efficient satellite image time series analysis: Combination of dynamic time warping and quasi-flat zones. In I. Society (Ed.), *IGARSS*, p. 4387–4390.