

Segmentation multi-échelle de séries temporelles d'images satellite : Application à l'étude d'une période de sécheresse au Sénégal.

T. Guyet^{1,3}H. Nicolas^{2,3}A. Diouck^{2,3}¹ AGROCAMPUS-OUEST/IRISA

65 rue de Saint-Brieuc, CS 84215, 35 042 Rennes Cedex

² AGROCAMPUS-OUEST/INRA, UMR1069 Sol Agro et hydrosystème Spatialisation³ Université européenne de Bretagne

thomas.guyet@agrocampus-ouest.fr, herve.nicolas@agrocampus-ouest.fr

Résumé

Les images satellite permettent l'acquisition d'information à grande échelle sur la végétation au sol. Ces images sont disponibles sur plusieurs années avec des fréquences d'acquisition importantes (1 image tous les seize jours) et forment ainsi des séries temporelles d'image satellite (SITS).

Dans ce travail, nous présentons une méthode pour segmenter une SITS en caractérisant l'évolution d'un indice de végétation (indice NDVI) sur deux échelles temporelles : annuelle et pluriannuelle.

Nous expérimentons cette méthode pour segmenter les régions sèches du Sénégal et comparons notre méthode à une classification directe des séries temporelles. Les résultats montrent que notre méthode différencie mieux des régions dans la zone médiane du Sénégal et localise des régions fines significatives (villes, forêts, zones agricoles).

Mots Clef

Image satellite, série temporelle, catégorisation

Abstract

Satellite images allow the acquisition of large-scale ground vegetation. Images are available along several years with a high acquisition frequency (1 image every two weeks). Such data are called satellite image time series (SITS).

In this work, we present a method to segment an image through the characterization of the evolution of a vegetation index (NDVI) on two scales : annual and multi-year.

We test this method to segment Senegal SITS and compare our method to a direct classification of time series. The results show that our method using two time scales better differentiates regions in the median zone of Senegal and locates fine interesting areas (cities, forests, agricultural areas).

Keywords

Remote sensing, time series, clustering

1 Introduction

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 c'est l'agriculture pluviale qui domine. Cette partie centrale de grande importance socio-économique est particulièrement sensible aux aléas climatiques et à leur variabilité interannuelle, accentuée par les changements climatiques globaux.

Dans ce contexte, cette étude a pour objectif d'analyser pour l'ensemble du Sénégal, l'évolution de l'état de la végétation sur une période de plusieurs années consécutives qui comprennent en particulier des années de sécheresse intense. Il s'agit d'effectuer une analyse spatio-temporelle de l'état de la végétation.

Les informations spatiales et temporelles sont issues de la télédétection, qui est incontournable pour obtenir des informations exhaustives et à très faible coût sur l'ensemble du territoire d'étude, souvent difficile d'accès. Les images de télédétection regroupent les images satellites et les images aériennes. Les images aériennes permettent des caractérisations plus précises, avec des échelles spatiales plus petites (de l'ordre du centimètre) mais plus coûteuses et limitées à de petites surfaces. Les images satellites peuvent couvrir de très grandes surfaces (surface d'un pays ou d'un continent) avec des précisions spatiales pouvant atteindre l'ordre du mètre mais offrent des caractérisations du sol moins fines et sont soumises à des phénomènes de masquage (par les nuages en particulier).

Nous avons retenu d'utiliser un indice de végétation, le *NDVI* (Normalized Difference Vegetation Index) qui est relié à la structure du couvert végétal, en particulier au taux de couverture du sol par la végétation, et à son contenu pigmentaire. Par ailleurs le *NDVI* est l'indice de végétation le plus utilisé par la communauté scientifique pour l'étude de la végétation. Il est défini par $NDVI = (PIR - R) / (PIR + R)$ avec *PIR* et *R* la réflectance¹ dans le

1. La réflectance est la proportion de la lumière incidente réfléchiée par une surface. Elle varie selon la longueur d'onde et le type de sol.

proche infrarouge et le rouge respectivement.




FIGURE 1 – Série temporelle d’images satellite (SITS). Au-dessus, vision sous la forme de couches d’image ; En dessous, vision transversale d’un pixel sous la forme d’une série temporelle (10 années de 23 points).

L’objectif d’effectuer le suivi d’un processus de surface à une large échelle spatiale (*i.e.* le Sénégal) oriente notre choix vers un système d’acquisition d’image de télédétection à temps de revisite d’un site court (journalier) et couvrant une large zone. Nous avons retenu le satellite AQUA et le capteur MODIS. La taille du pixel au sol est de 250mx250m dans le rouge et le proche infrarouge. Des synthèses d’images journalières ont été réalisées par périodes de 16 jours pour tenir compte de l’ennuage et obtenir ainsi des séries temporelles d’images quasi régulières tout au long de la période d’étude qui s’étend de janvier 2001 à décembre 2008.

L’ensemble de ces images constitue une série temporelle d’images satellite (ou Satellite Image Time Series – SITS). Vue transversalement, chaque pixel est associé à une série temporelle. La Figure 1 illustre ces deux visions d’une SITS.

L’analyse de ces nouvelles données répond à la fois au problème de caractérisation de l’évolution d’une zone géographique et également à celui de la prévision de son évolution. Parmi les nombreuses applications agronomiques de ces données, on peut donner comme exemple le suivi des changements des surfaces (cultures [3], eau, ...), le suivi de la progression spatiale de la végétation, des forêts ou des bâtis (urbanisation) [11], l’analyse des changements abrupts ou encore l’analyse des conséquences des changements climatiques.

Dans ce travail, nous nous intéressons à la segmentation d’une série temporelle d’images satellites selon l’évolution de la sécheresse du sol à long terme. Contrairement à une analyse d’image instantanée, l’analyse d’une SITS permet de caractériser la dynamique d’un phénomène. Pour tenir

compte de la saisonnalité des données, l’approche que nous proposons caractérise la dynamique de la végétation sur deux échelles temporelles : annuelle et pluriannuelle.

2 Travaux proches

L’objectif de la segmentation est de déterminer les régions homogènes d’une image, correspondant à différentes caractéristiques du sol. La catégorisation des pixels est une méthode non-supervisée usuelle pour segmenter automatiquement une image satellite.

Dans le domaine de la télédétection, il est assez usuel d’avoir à classer des pixels dont l’information est plus riche que les trois dimensions (RVB) des images visuelles. Les images hyperspectrales sont généralement traitées par réduction de la dimension puis par catégorisation [12]. La réduction est obtenue par des méthodes statistiques. Dans notre approche, les pixels sont associés à des séries temporelles de grande dimension. Les dimensions ne sont pas indépendantes les unes des autres, les méthodes statistiques de réduction de la dimension ne donnent donc pas de résultats interprétables. Des méthodes spécifiques aux SITS sont donc nécessaires.

Une littérature importante s’intéresse à la détection de changements dans les séries temporelles. L’objectif de ces travaux est de proposer des méthodes de localisation de changements abrupts. De Beurk et Henebry [3] proposent un cadre statistique pour analyser les discontinuités dans de longues séries temporelles d’images en utilisant des méthodes issues de l’analyse de séries temporelles. La méthode BFAST [16] prend en compte les changements saisonniers et les tendances pour améliorer la précision des méthodes de détection de changement en présence de variations climatiques importantes.

Ces méthodes répondent à une question précise : celle de la localisation d’un changement abrupt. Ce changement étant défini a priori (explicitement ou non).

Les méthodes qui utilisent la fouille de motifs séquentiels cherchent à identifier des motifs fréquents, *i.e.* une succession d’états d’un pixel qui se retrouve fréquemment dans l’image. Petitjean et *al.* [11] appliquent une méthode de fouille de séquence à l’urbanisation en périphérie des villes pour fournir une visualisation intuitive des changements. Julea et *al.* [7] extraient des motifs fréquents par groupes de pixels co-localisés. Cette méthode affine la caractérisation de pixels en utilisant des informations sur les pixels géographiquement voisins. La méthode de Ding et *al.* [5] caractérise le changement en apprenant un modèle Markovien de la succession des classes de sécheresse. Ces classes de sécheresse étant obtenues par une caractérisation floue de l’indice *NDVI*. L’hypothèse Markovienne utilisée permet de tenir compte des successions d’ordre 1.

Dans tous ces travaux, il s’agit d’identifier des dynamiques qui sont fréquemment rencontrées dans une zone géographique. Elles conduisent à une modélisation de l’information des changements. Mais les méthodes de fouille de

motifs ne répondent pas au problème de segmentation de l'image. Seule une faible proportion des pixels d'une image se voit attribuer une signification et, si la séquence d'un même pixel correspond à deux motifs, alors le pixel est associé aux deux motifs.

L'approche que nous proposons s'inspire des travaux en abstraction des séries temporelles [14] qui cherchent à construire des abstractions symboliques des séries temporelles pour les rendre plus facilement interprétables. Parmi ces travaux, certains s'intéressent spécifiquement à des approches multi-échelles temporelles [1] ou multi-échelles symboliques [15]. À notre connaissance, il n'existe pas de méthodes qui cherchent à prendre en compte plusieurs échelles temporelles dans l'analyse de SITS.

3 Présentation de la méthode

La méthode présentée associe chaque pixel de l'image à une classe de séquences de profils annuels. Pour cela, elle procède selon deux étapes successives de catégorisation (cf. schéma de la Figure 2) :

1. la **caractérisation des profils annuels** à partir de l'ensemble des séries temporelles annuelles, ainsi que la construction des images annuelles correspondantes ;
2. la **construction des classes des séquences** et la construction d'une image de la segmentation finale attribuant chaque pixel à une classe de séquences.

Dans toute la suite de cet article, nous noterons $\mathcal{I} = (I_i^j)_{i=1..n, j=1..m}$ la SITS composée de $n \times m$ couches où n est le nombre d'années couvertes par la SITS et m est le nombre d'images par année. I_i^j désigne alors la couche de la j -ème image de l'année i , et $I_i^j(x, y)$ désigne le pixel aux coordonnées (x, y) de cette couche. Une **couche** est une image unidimensionnelle, donc $I_i^j(x, y)$ est une valeur réelle. On introduit également la notation $I_i(x, y) \in \mathbb{R}^m$ qui désigne la série temporelle aux coordonnées (x, y) de l'année i . Par la suite, une telle série temporelle est dénommée **profil annuel**.

3.1 Construction d'une image de profils annuels caractéristiques

La construction d'une image de profils annuels est décrite dans l'Algorithme 1. Cette méthode comporte deux étapes : l'extraction des profils annuels par catégorisation des séries temporelles annuelles et la construction d'une image avec une couche par année dont chaque pixel contiendra l'identifiant du profil annuel.

La première étape (lignes 1 à 5) construit des catégories de profils annuels. La distance utilisée entre les profils annuels est une distance Euclidienne. La date dans l'année est importante pour caractériser le type d'année. Le début du pic végétal annuel est un indicateur de la sécheresse. Plus celui-ci est tardif, plus l'année sera sèche. La distance Euclidienne est plus appropriée que d'autres

mesures élastiques (e.g. DTW [13], LCSS [2] ou MVM [9]) pour traduire ces informations. L'utilisation de la distance Euclidienne entre les profils annuels permet l'utilisation d'une large gamme d'algorithmes de catégorisation de l'ensemble E : Affinity Propagation [6], SVM. Nous avons choisi d'utiliser l'algorithme des KMeans [10] pour sa simplicité d'implémentation et sa capacité à traiter de grands ensembles de données.

L'ensemble E est construit en utilisant des profils annuels issus de toutes les années de \mathcal{I} . À cette étape du traitement, il n'est pas fait de distinction entre les années. En procédant ainsi, on souhaite apporter une distance plus significative entre pixels.

Le résultat obtenu par l'algorithme des KMeans est l'ensemble des k de profils annuels moyens (k étant fixé par l'utilisateur). On utilise un critère d'arrêt de la méthode basé sur le taux d'amélioration de l'erreur quadratique moyenne entre deux itérations. Les centroïdes obtenus par l'algorithme sont appelés les **profils annuels caractéristiques** de chaque catégorie.

Un sous-échantillonnage spatial est effectué pour réduire le nombre de profils annuels à classer (cf. ligne 3 où $Ech(\mathcal{I})$ désigne l'échantillonnage de \mathcal{I}). Ce sous-échantillonnage est réalisé soit en utilisant une sous-partie de l'image, soit en prélevant de manière régulière des pixels dans l'image, soit en combinant ces deux méthodes de sous-échantillonnage.

Le sous-échantillonnage permet d'abord de limiter l'usage de mémoire qui dépasserait les capacités de l'architecture matérielle utilisée. Dans la mesure où le nombre total de profils annuels est très important (un profil annuel par année et par pixel, soit environ 250.10^6 profils sur nos données), la mémoire nécessaire pour la classification est très importante². Le dépassement de la mémoire de travail dégrade de manière rédhibitoire les performances de calcul [17].

Le sous-échantillonnage a également pour intérêt de présélectionner les parties de l'image les plus intéressantes pour faire la catégorisation. Comme indiqué en introduction, les parties nord et sud sont connues pour être très homogènes, il n'est donc pas utile de classer l'ensemble de ces pixels très redondants. Il est plus intéressant de prélever plus de pixels dans la région centrale de l'image dans laquelle il y a plus de variabilité.

En contrepartie du sous-échantillonnage, une étape supplémentaire d'attribution des classes aux pixels de \mathcal{I} est nécessaire (cf. lignes 6 à 9 de l'Algorithme 1). Pour chaque année i , l'algorithme construit une couche A_i dont les pixels sont obtenus en récupérant l'**identifiant de la catégorie** (p_1, p_2, \dots, p_k) dont le profil annuel caractéristique et le plus proche du profil annuel du pixel. L'image \mathcal{A} est donc composée de n couches (1 couche par année) dont les valeurs sont des

2. avec de telles données, la mémoire nécessaire dépasse la capacité des processeurs de calculs à notre disposition disposant pourtant de 48Go.




FIGURE 2 – Illustration de la méthode adoptée.

Algorithme 1 : Catégorisation des profils annuels

Entrées : \mathcal{I} : une SITS, k : nombre de catégories
Sorties : \mathcal{A} : une SITS de n couches, $\mathcal{P} = (p_i)_{i=1..k}$: centroïdes des catégories de profil annuel

```

// Catégorisation
1  $E = \emptyset$ 
2 for  $i \in 1..n$  do
3   forall  $(x, y) \in Ech(\mathcal{I})$  do
4      $E = E \cup I_i(x, y)$ 
5  $\mathcal{P} = \text{KMeans}(E, k)$ 
// Construction d'une image  $\mathcal{A}$  par attribution
// des classes
6  $sort(\mathcal{P})$ 
7 for  $j \in 1..n$  do
8   forall  $(x, y)$  do
9      $A_j(x, y) = \underset{p \in \mathcal{P}}{\operatorname{argmin}} ((p - I_j(x, y))^2)$ 

```

indices de catégories de profil annuel.

Les profils annuels ont été préalablement organisés (cf. ligne 6), p_1 correspondant au profil dont la moyenne est la plus petite, i.e. une année sèche, p_2 étant ensuite le profil le plus proche de p_1 , etc. On ne peut pas affirmer formellement que la catégorie p_2 est plus proche de la catégorie p_5 que de la catégorie p_8 . Néanmoins, on observe que l'ordre reconstruit sur les séries temporelles approche l'ordre des années les plus sèches vers les plus humides. Cette étape facilite les interprétations des résultats, mais n'a pas de conséquence sur la suite du processus.

3.2 Construction des classes de séquences

Chaque pixel (x, y) de l'image \mathcal{A} est caractérisé par une séquence, notée $\mathcal{A}(x, y) = (a_i)_{i \in 1..n}$, de n identifiants de profils annuels ($\forall i, a_i \in \{p_1, p_2, \dots, p_k\}$).

La construction des classes de séquences consiste à regrouper de séquences similaires. La distance entre deux séquences $a = (a_i)_{i \in 1..n}$ et $b = (b_i)_{i \in 1..n}$ est donnée par la formule suivante :

$$\forall (i, j), d_s(a, b) = \sqrt{\sum_{u=1}^n D_p(a_u, b_u)^2}$$

où D_p est une matrice de distance construite en calculant les distances Euclidiennes deux à deux entre les profils annuels caractéristiques.

L'algorithme de catégorisation utilisé pour construire les classes de séquences similaires est l'algorithme des KMedoids [8]. La mesure d_s est une distance vérifiant, en particulier, l'inégalité triangulaire. Cette propriété est nécessaire pour utiliser les algorithmes de classification usuels. Mais l'algorithme KMeans ne peut pas être utilisé pour ces données symboliques [4]. Dans cet algorithme, la construction des centroïdes des catégories passe par un calcul de moyennes qui n'a pas de signification dans le cas de données symboliques. Des algorithmes, tels que les KMedoid et Affinity Propagation [6], utilisant des instances comme prototype d'une catégorie résolvent ce problème. Nous avons préféré les KMedoid à l'algorithme Affinity Propagation car ce dernier nécessite la construction d'une matrice de distances entre tous les exemples à classer. Cette matrice serait d'une taille trop importante pour pouvoir classer les exemples.

Chaque classe C_i , $i \in 1..l$ est représentée par l'ensemble des séquences qui s'y trouvent. L'image de la segmentation finale, \mathcal{S} , est obtenue en donnant la classe d'appartenance de la sequence de chaque pixel :

$$\forall x, y, \mathcal{S}(x, y) = \underset{i \in \{1..l\}}{\operatorname{argmin}} (d_s(C_i, \mathcal{A}(x, y)))$$

4 Résultats

4.1 Données et paramètres

Les SITS utilisées pour ce travail sont issues d'images de l'indice $NDVI$ calculées à partir d'images satellites

(images MODIS³) du Sénégal avec une précision de 250m. Chaque image est de taille 5137x4828. L'ensemble des images forme une série temporelle d'images pendant 7 ans (de 2001 à 2008) à raison de 23 images par année.

Pour ces expérimentations, nous avons choisis $k = 30$ et $l = 100$. Pour la catégorisation des profils annuels, nous avons utilisé un échantillonnage régulier d'un pixel traité sur 20.

4.2 Construction des profils annuels

La Figure 3 illustre 5 profils de classes sur les 30 obtenus à partir des profils des années 2001 à 2008 du Sénégal. La Figure 4 illustre la localisation spatio-temporelle de ces classes. Sur cette dernière Figure, on ne localise que les 5 classes présentées sur le graphe de la Figure 3, mais la totalité de l'image a été segmentée. On restreint également à la présentation des 4 premières années choisies pour la présence, en 2002, d'une sécheresse importante.




FIGURE 3 – Profils annuels

La classe C_1 correspond au profil de l'eau (très faible réflectance tout au long de l'année). On retrouve cette classe localisée sur les fleuves et les lacs sur toutes les années de la Figure 4. La classe C_4 correspond à des zones sèches (peu de végétation). Ces zones sont situées au sud. Les années 2002 et 2003 ont été des années de sécheresse importante. On note que sur ces images la classe C_4 apparaît de manière plus importante et se situe plus au sud. En 2002, les régions tout à fait en haut de l'image ont été associées à d'autres classes de sécheresse (C_2 ou C_3). Les classes C_8 , C_{11} apparaissent à des latitudes centrales. C_8 correspond à une zone plus sèche que C_{11} . Pour C_8 , on constate sur le profil annuel (cf. Figure 3) que cette classe correspond à une végétation plus tardive que C_{11} , et sur une moins longue période. En fonction des années, la répartition de ces classes dans la zone centrale du Sénégal varie beaucoup. En 2002 et 2004, la classe C_{11} est majoritaire. En 2002, C_8 disparaît quasiment au profit de classes "plus sèches" comme C_{11} et en 2003, ces classes sont également réparties, l'une à l'est et l'autre à l'ouest. Finalement, la classe C_{27} est associée à des régions avec beaucoup de végétation. Elle est située dans la Casamance, au sud-ouest du Sénégal. Cette région est humide, composée de forêts,

3. voir modis.gsfc.nasa.gov/ pour plus de détails à propos des images MODIS.

de fleuves et de rivières. Les zones identifiées dans cette classe sont géographiquement stables dans le temps.

Une des spécificités de notre méthode est de classer les profils annuels en mélangeant les différentes années. Ces illustrations montrent que ces classes sont bien partagées par plusieurs années. On peut ainsi mettre en évidence des phénomènes spatio-temporels. Certaines classes, comme la classe C_{27} , montrent des dynamiques locales (spécifiques à une zone et stable dans le temps). Tandis que d'autres classes permettent d'observer des phénomènes dans le temps : la migration de la classe C_4 vers le sud montre une année particulièrement sèche. En mélangeant toutes les années, l'absence d'une classe sur une image est également informative. On note ainsi la quasi-absence de la classe C_8 en 2001 et 2004. Cette classe est donc assez caractéristique des années 2002 et 2003.

4.3 Construction des classes de séquences

À l'échelle du Sénégal et pour 30 profils annuels sur 8 années, il y a 431717 séquences différentes. La classification des séquences vise à réduire ce nombre pour segmenter l'image en zones uniformes. La Figure 5 à gauche illustre le résultat de notre méthode après une classification à 100 classes. Sur les 100 classes seules 73 classes sont effectivement présentes dans l'image. Pour des classifications avec des nombres de classe différents (50 et 200), les matrices de confusion montrent une bonne stabilité de la méthode.

La Figure 5 à droite montre les résultats obtenus par une classification des séries temporelles sur les dix années. Nous avons utilisé l'algorithme K-Means, avec 100 classes également, en utilisant une distance Euclidienne entre les séries temporelles de 230 points. La Figure 6 montre les distributions de pixels obtenus pour les deux images.




FIGURE 6 – Distribution des pixels par classe pour les méthodes de catégorisation des séquences (trait plein) et des séries temporelles (trait pointillé). Pour les séries temporelles, la classe 95 comporte 3521923 pixels (non visualisée pour des raisons d'échelle)

Le résultat obtenu avec notre méthode de classification des séquences de profils annuels permet de mieux segmenter la

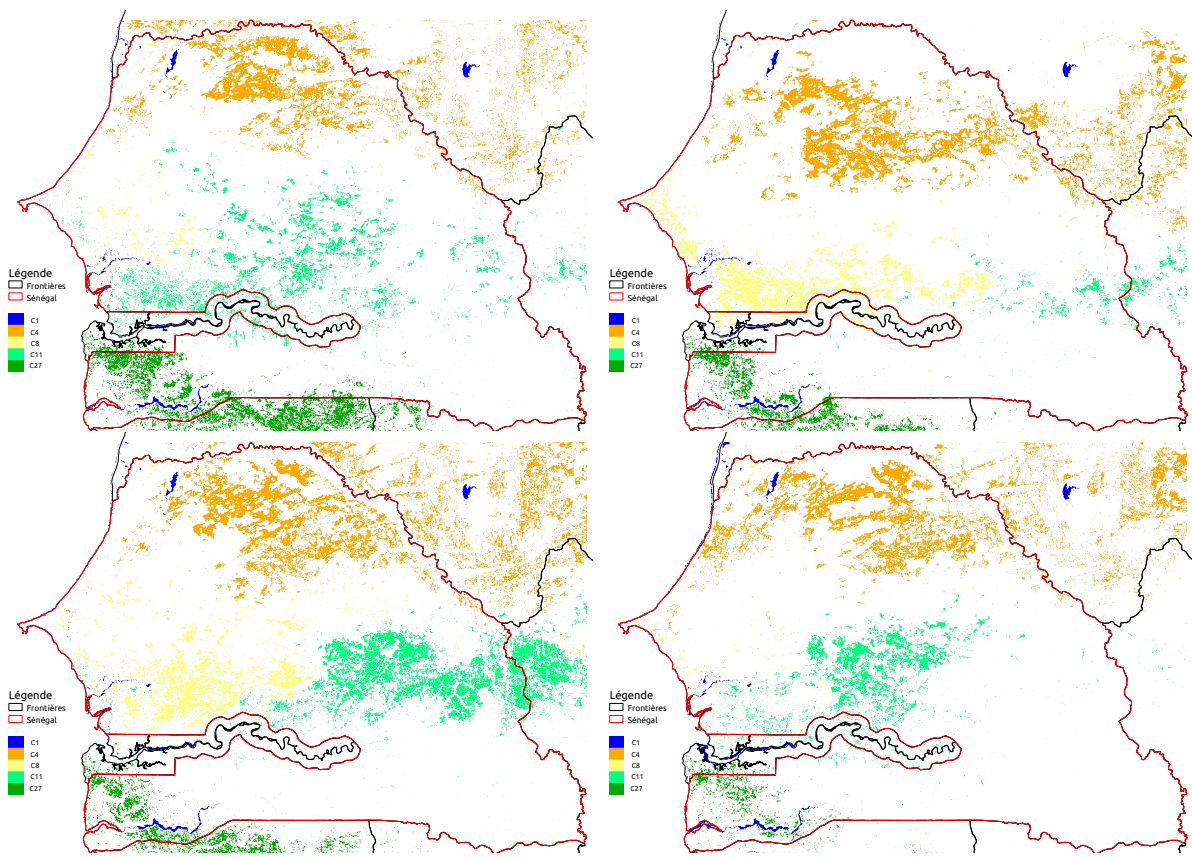


FIGURE 4 – Localisation des classes de la Figure 3 sur 4 années 2001 à 2004 (de gauche à droite, puis de haut en bas). Bleu : C_1 , orange : C_4 , jaune : C_8 , vert clair : C_{11} , vert : C_{27} . Le trait rouge visualise les limites administratives du Sénégal.

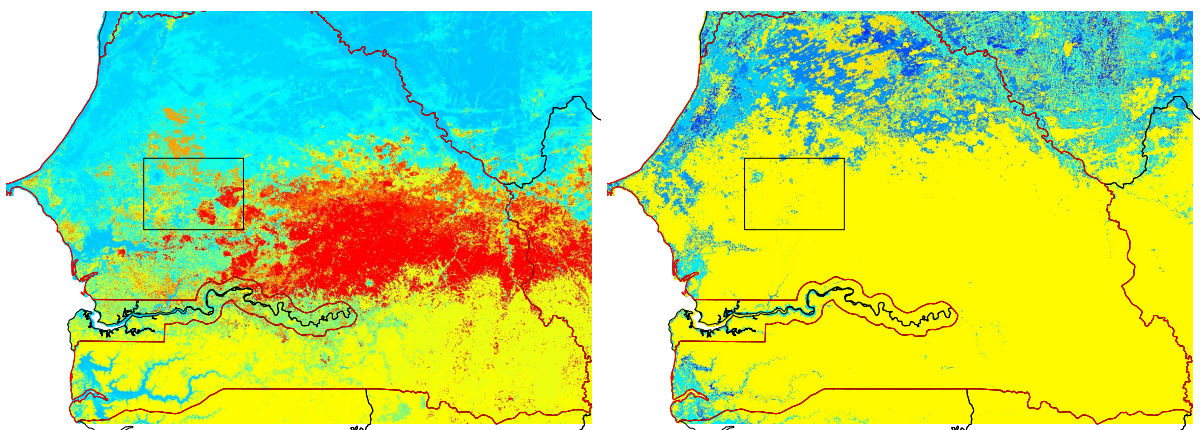


FIGURE 5 – Résultats finaux de la segmentation de la SITS pour 100 classes. À gauche, résultat par classification des séquences de profils annuels. À droite, résultat par classification directe des séries temporelles. Le rectangle noir localise une région comprenant la ville de Touba et le territoire de Kelkome.

région médiane du Sénégal que la méthode de classification directe des séries temporelles. La segmentation obtenue par la classification des séries temporelles montre que toute la région médiane du Sénégal est regroupée dans une même classe (classe 95). Sur la distribution (cf. Figure 6), cette classe représente plus de 66% des pixels utiles⁴ de l'image. L'utilisation de la distance Euclidienne sur toute la série temporelle ne permet pas de différencier les comportements fins de ces régions par rapport à une différence de valeur moyenne entre les séries temporelles. En revanche, en utilisant la classification des séquences, la méthode permet de segmenter la région médiane du Sénégal en plusieurs zones avec des dynamiques différentes. La distribution des pixels (cf. Figure 6) montre une meilleure répartition des classes dans laquelle 12 classes représentent au moins 10^5 pixels.

La classe 67 (pixels rouges à l'est sur la Figure 5 à gauche) a une séquence médiane $(p_{15}p_{17}p_{10}p_{14}p_{14}p_{10}p_{10})$. La classe 59 $(p_9p_{17}p_8p_{10}p_{10}p_9p_9)$ (pixels orange au nord ouest) correspondent à deux régions qui ont une évolution similaire sur les 7 ans : une sécheresse en 2002 (classe p_{17}) et une année 2003 plus humide que les autres années. Ces classes se différencient des années "normales" par leurs profils annuels.

Notre méthode permet également de retrouver, par une approche globale, des segmentations fines des régions locales. À proximité de la ville de Touba, la région de Kelkome est une région agricole (cf. rectangle noir de la Figure 5 pour la localisation). La Figure 7 montre trois images de cette région obtenues avec différentes méthodes. Sur l'image de classification par les séries temporelles, seule la ville de Touba est distinguée. Sur l'image obtenue par classification globale, on identifie la ville de Touba (faible végétation toutes les années) et en bas à droite de l'image des forêts limitrophes des zones d'agriculture. Sur la dernière image, le processus global de segmentation a été appliqué uniquement sur cette portion du Sénégal (avec $k = 20$ et $l = 40$). Les profils annuels et les classes de séquences qui ont été obtenus sont donc très spécifiques à cette région. La segmentation obtenue est donc plus fine : les forêts sont plus clairement séparées des zones de culture, et d'autres régions, initialement identifiées comme identiques se distinguent sur cette image. S'il est normal qu'un traitement localisé permette une meilleure segmentation d'une région, il faut noter que notre méthode globale a correctement identifié certains des éléments fins (forêts, villes, zones de cultures) là où la méthode par classification des séries temporelles n'a pu le faire.

5 Conclusion et perspectives

Nous avons présenté une méthode de segmentation de séries temporelles d'images satellite basée sur l'évolution des indices de végétation (indice $NDVI$) sur une longue durée (7 ans). La spécificité de la méthode réside dans la

4. Les pixels inutiles sont les pixels localisés dans l'océan.




FIGURE 7 – Segmentation locale de la région entre Touba et le territoire de Kelkome. De haut en bas, résultat de la segmentation par la méthode avec séquences uniquement de cette région, zoom sur l'image de la classification des séquences, zoom sur l'image obtenue par classification des séries temporelles.

construction, d'une part, de profils annuels caractéristiques pour caractériser le comportement de chaque année pour chaque pixel et, d'autre part, de segmenter l'image en catégorisant les séquences des profils annuels caractéristiques.

Les résultats obtenus pour la segmentation du Sénégal montrent des résultats qualitativement meilleurs qu'une classification directe des séries temporelles que portent les pixels. La segmentation a permis de distinguer des régions de la zone médiane du Sénégal avec des comportements différents et de retrouver des éléments fins pertinents dans les images (forêts, villes, zones agricoles).

Ce travail montre que l'utilisation de méthodes multi-échelles pour des données avec des résolutions fines permet d'obtenir de meilleurs résultats que certaines méthodes directes. Ce travail s'étant focalisé sur la dimension temporelle, l'une des perspectives de ce travail est d'intégrer des traitements à plusieurs échelles spatiales pour affiner la classification. Nous travaillons également à l'extension de la méthode à plusieurs indicateurs complémentaires (NDVI, NDII, ...) pour améliorer les résultats de segmentation.

La grande dimension des données représente encore un défi important. Des améliorations doivent être apportées aux méthodes pour réduire les temps de calcul. Nous envisageons ainsi d'utiliser la méthode LibLinear [17] permettant une catégorisation SVM avec un très grand nombre d'exemples.

Finalement, l'un des objectifs de ce travail est de prédire l'évolution des sols en fonction des précipitations. Nous cherchons maintenant à mettre en place une méthode permettant de faire des prédictions locales de l'évolution à court terme des sécheresses en utilisant une "régionalisation" à l'aide de l'image de segmentation par les séquences sur plusieurs années et l'utilisation des profils annuels "locaux" pour réaliser des prévisions à 16 jours.

Références

- [1] N. Castro and P. Azevedo. Multiresolution motif discovery in time series. In *Proceedings of the SIAM International Conference on Data Mining*, pages 665–676, 2010.
- [2] G. Das, D. Gunopoulos, and H. Mannila. Finding similar time series. In *Proceedings of the first PKDD Symposium*, pages 88–100, 1997.
- [3] K. M. de Beurs and G. M. Henebry. A statistical framework for the analysis of long image time series. *International Journal of Remote Sensing*, 28(8) :1551–1573, 2005.
- [4] E. Diday and N. Murty. *Encyclopedia of Data Warehousing and Mining*, chapter Symbolic Data Clustering. Idea Group Reference Publisher, 2005.
- [5] S. Ding, C. Rulinda, A. Stein, and W. Bijker. NDVI time series and markov chains to model the change of fuzzy vegetative drought classes. In *Proceedings of Proceedings of Analysis of Multi-temporal Remote Sensing Images*, 2011.
- [6] B. J. Frey and D. Dueck. Clustering by passing messages between data points. *Science*, 315 :972–976, 2007.
- [7] A. Julea, N. Méger, P. Bolon, C. Rigotti, M.-P. Doin, C. Lasserre, E. Trouvé, and V. Lazarescu. Unsupervised Spatiotemporal Mining of Satellite Image Time Series Using Grouped Frequent Sequential Patterns. *Transactions on Geoscience and Remote Sensing*, 49(4) :1417–1430, 2011.
- [8] L. Kaufman and P. J. Rousseeuw. *Finding Groups in Data : An Introduction to Cluster Analysis*. 1990.
- [9] L. J. Latecki, V. Megalooikonomou, Q. Wang, R. Lakämper, C. Ratanamahatana, and E. J. Keogh. Partial elastic matching of time series. In *ICDM'05*, pages 701–704, 2005.
- [10] J. MacQueen. Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, pages 281–297, 1967.
- [11] F. Petitjean, P. Gançarski, F. Masseglia, and G. Forestier. Analysing satellite image time series by means of pattern mining. In C. Fyfe, P. Tino, D. Charles, C. Garcia-Osorio, and H. Yin, editors, *Intelligent Data Engineering and Automated Learning (IDEAL)*, volume 6283 of *Lecture Notes in Computer Science*, pages 45–52. Springer Berlin / Heidelberg, 2010.
- [12] A. Plaza, J. A. Benediktsson, J. W. Boardman, J. Brazile, L. Bruzzone, G. Camps-Valls, J. Chanussot, M. Fauvel, P. Gamba, A. Gualtieri, M. Marconcini, J. C. Tilton, and G. Trianni. Recent advances in techniques for hyperspectral image processing. *Remote Sensing of Environment*, 113(Supplement 1) :S110–S122, 2009. Imaging Spectroscopy Special Issue.
- [13] H. Sakoe and S. Chiba. Dynamic programming algorithm optimization for spoken word recognition. *IEEE Transactions on Speech and Signal Processing*, 26(1) :43–49, 1978.
- [14] Y. Shahar. A framework for knowledge-based temporal abstraction. *Artificial Intelligence*, 90(1-2) :79–133, 1997.
- [15] J. Shieh and E. J. Keogh. iSAX : indexing and mining terabyte sized time series. In *Proceeding of the 14th international conference on Knowledge discovery and data mining (ACM SIGKDD)*, pages 623–631, 2008.
- [16] J. Verbesselt, R. Hyndman, G. Newnham, and D. Culvenor. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, 114(1) :106–115, 2010.
- [17] H.-F. Yu, C.-J. Hsieh, K.-W. Chang, and C.-J. Lin. Large linear classification when data cannot fit in memory. In *Proceeding of the 16th international conference on Knowledge discovery and data mining (ACM SIGKDD)*, pages 833–842, 2010.