

# Analyse des dynamiques spatio-temporelles à partir de séries temporelles d'images satellitaires

Lynda Khiali\*, Dino Ienco\*,\*\* et Maguelonne Teisseire \*

\*Irstea, UMR TETIS, Montpellier, France  
{lynda.khiali,dino.ienco,maguelonne.teisseire}@irstea.fr  
<http://www.irstea.fr>

\*\*LIRMM, Montpellier, France  
<http://www.lirmm.fr>

**Résumé.** La télédétection est un domaine qui regroupe les techniques et les outils permettant l'observation de la terre, notamment l'acquisition d'images satellitaires. La méthode proposée dans cet article permet une analyse automatique de séries temporelles de telles images. Nos travaux introduisent une nouvelle approche pour l'analyse et le clustering de Séries Temporelles d'Images Satellitaire (STIS). Ce processus se divise en deux parties. Dans un premier temps, nous retraçons les changements radiométriques d'une zone en représentant son évolution au cours du temps par un graphe dit *graphe d'évolution*. Dans un deuxième temps, nous introduisons une représentation synthétique des *graphes d'évolutions* afin de pouvoir appliquer un algorithme de clustering permettant un regroupement par types d'évolutions identifiées. Les expérimentations menées nous ont permis de valider notre approche sur une zone d'étude.

## 1 Introduction

De nos jours, les satellites permettent de collecter un énorme volume de données d'observation de la Terre (Nativi et al., 2015). Les images satellitaires peuvent être utilisées pour la surveillance à distance des phénomènes artificiels et naturels tels que la croissance des zones urbaines, les changements dans les habitats naturels, l'évolution de l'utilisation des terres agricoles et les effets du changement climatique. La tâche de surveillance est réalisée en considérant des séries temporelles d'images satellitaires où la même zone spatiale est représentée à différentes estampilles temporelles. L'étude standard de ce type de données réalise principalement la surveillance de phénomènes indépendamment de leur évolution au cours du temps (Batista et al., 2014). Cependant, il est important de tenir compte de la dimension temporelle caractérisant l'évolution des données ainsi que de leurs interactions spatiales. Un autre défi lié à l'analyse des images satellitaires est le niveau de granularité décrivant les phénomènes d'intérêt (Blaschke, 2010). Récemment, (Blaschke, 2010) a mis l'accent sur l'analyse basée sur les objets des images satellitaires plutôt que sur les pixels. Ces méthodes ne traitent plus le pixel de manière isolée mais des groupes de pixels (objets).

Cet article est organisé comme suit. La section 2 explore les travaux connexes dans le domaine de l'analyse de séries temporelles avec un accent particulier sur les données satellitaires.

L'approche proposée est décrite dans la section 3. La section 4 introduit la zone d'étude choisie pour les expérimentations et fournit des détails sur le pré-traitement des données. Les évaluations quantitatives et qualitatives sont présentées dans la section 5. Enfin, la section 6 conclut l'étude.

## 2 État de l'art

Dans la littérature, il existe de nombreuses propositions pour l'analyse des séries temporelles d'images satellitaires (STIS) (Zhu et al., 2012; Batista et al., 2014; Rakthanmanon et al., 2012; Petitjean et al., 2012a,b). La plupart de ces approches utilisent des algorithmes classiques de classification avec une nouvelle mesure de similarité (distance) entre les séries temporelles. Une des mesures les plus connues est Dynamic Time Warping (DTW) (Rakthanmanon et al., 2013). Cette mesure permet de calculer une correspondance optimale entre deux séries temporelles de données. Elle est habituellement utilisée pour les séries temporelles longues qui ne peuvent pas être alignées temporellement et qui peuvent contenir du bruit. Cependant, son coût de calcul est élevé. Dans (Zhu et al., 2012), les auteurs proposent un moyen approximatif de calculer DTW.

Dans (Batista et al., 2014), les auteurs proposent une nouvelle mesure de distance invariante de complexité efficace. Le choix d'une bonne mesure de similarité est plus important que le choix de l'algorithme de clustering pour certains types particuliers de séries temporelles. La mesure proposée semble adaptée pour le clustering des séries temporelles, mais elle considère les objets comme indépendants les uns des autres, alors que les données d'images satellitaires comptent des instances corrélées spatialement entre elles.

Considérant le problème du clustering des STIS, (Petitjean et al., 2012a) propose une approche qui traite des séries temporelles irrégulières. Celle-ci utilise DTW sur des séries temporelles avec des pixels multivariés. Chaque série temporelle de pixel est une séquence de tuples de valeurs radiométriques associées à un pixel particulier dans une certaine estampille temporelle. Cette dernière est robuste sur des séries temporelles bruitées et de longueurs différentes. Contrairement aux approches précédentes, (Petitjean et al., 2012b) introduit une méthodologie d'analyse spatio-temporelle qui combine des informations au niveau pixel et objet. Tout d'abord une segmentation est effectuée sur chaque image, puis la série temporelle du pixel est enrichie avec l'information de l'objet segmenté auquel il appartient afin de lier les pixels appartenant au même objet. Cette méthode peut être considérée comme une première étape vers l'analyse par objet mais l'unité élémentaire considérée est néanmoins le pixel.

Dans (Qin et al., 2013), les auteurs présentent une approche de détection des changements de couverture du sol basée sur les objets. Cette méthode permet d'analyser une série temporelle composée de seulement deux images hétérogènes issues de capteur différents. Les images sont d'abord juxtaposées puis segmentées et les objets résultats sont ensuite classés afin de générer une cartographie des changements de couverture du sol.

## 3 Méthode

Dans cette section, nous donnons d'abord un aperçu général de la méthode proposée, puis nous détaillons chacune des étapes.

### 3.1 Schéma Général :

Les étapes du processus global proposé sont décrites dans la figure 1. Les images en entrée se présentent sous forme d'une STIS couvrant la même zone géographique au cours du temps, permettant ainsi le suivi de son évolution. Les images de la série étant alignées, leur couverture est modélisée par une grille de pixels.

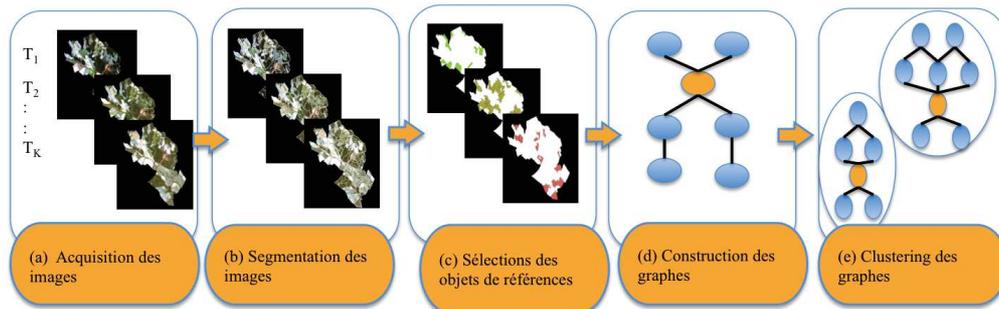


FIG. 1 – Schéma général des différentes étapes de clustering des graphes d'évolutions.

Une fois la STIS acquise (Fig. 1(a)), la première étape est la segmentation, qui vise à générer des objets représentatifs d'entités du monde réel (Fig. 1(b)). L'ensemble d'objets générés est alors filtré pour sélectionner un sous-ensemble, nommé *objets de références* (Fig 1(c)). Un *graphe d'évolution* est ensuite construit pour chaque *objet de référence* permettant ainsi le suivi de son évolution radiométrique. Une fois les graphes construits, ils sont transformés en une représentation synthétique qui permettra par la suite de leur appliquer un algorithme de clustering (Fig 1(d)). La finalité du processus est de mettre en évidence les différents types d'évolutions.

### 3.2 Segmenttaion des images

Les image de la série sont d'abord pré-traitées. Le pré-traitement compte principalement les deux étapes suivantes :

- *Corrections radiométriques* : En raison des nuages ou des artefacts du capteur, les valeurs radiométriques des pixels doivent être normalisées et mises à l'échelle (Lillesand et al., 2008) ;
- *Extractions d'indices* : Généralement, dans le domaine de la télédétection, des nouvelles variables sont dérivées de la combinaison des bandes brutes originales (c'est-à-dire NDVI (Jr et al., 1974), VSDI (Zhang et al., 2013)). Ces informations sont ajoutées à l'ensemble d'attributs décrivant les pixels ou les segments.

Les images sont ensuite segmentées selon une analyse par objets (OBIA) où un segment (objet) représente un ensemble de pixels contigus.

L'objectif de la segmentation est de créer une représentation de l'image, plus significative et plus facile à analyser. Cette approche est inspirée de l'interprétation visuelle humaine

d'images numériques où la couleur, la forme, la taille, la texture et l'information contextuelle sont utilisées pour détecter des modèles à différentes échelles (Lillesand et al., 2008).

La segmentation d'image résulte en un ensemble de segments qui couvrent collectivement l'image entière sans chevauchement. Dans ce travail, la segmentation d'image est réalisée avec l'algorithme de segmentation multirésolution<sup>1</sup>. Cet algorithme est disponible dans l'outil eCognition Developer 8.8.1. Notant que chaque image est segmentée indépendamment des autres images de la série temporelle.

### 3.3 Préliminaires et notations

L'approche proposée manipule une STIS. Une STIS est définie comme étant un ensemble d'images ordonnées dans le temps ( $I_1, I_2, \dots, I_T$ ) où l'index représente l'estampille temporelle de chaque image. Ainsi les images couvrent la même zone à travers le temps et permettent de suivre son évolution.

A chaque image de la série est associée un ensemble d'objets générés lors de la segmentation, noté  $O_t = \{o_t^i\}_{i=1}^{|O_t|}$  tel que,  $t$  représente l'estampille temporelle de l'image et  $i$  le numéro du segment. Nous notons par  $\mathcal{O}$ , l'union de tous les objets identifiés dans la série temporelle toutes images confondues ( $\mathcal{O} = \bigcup_{t=1}^T O_t$ ), sachant que le nombre de segments identifiés pour chaque image est différent. Pour chaque objet, il est identifié deux informations qui sont l'ensemble des pixels dont il se compose ( $Pix(o_t^i)$ ) et un vecteur d'attributs relatif à son information radiométrique ( $Info(o_t^i)$ ). Les valeurs radiométriques de l'objet sont calculées en moyennant celles des pixels qui le composent.

### 3.4 Suivi de l'évolution spatio-temporelle des zones géographiques :

Dans (Guttler et al., 2014), les auteurs proposent une approche automatique pour le suivi de l'évolution des zones en utilisant des séries temporelles d'images satellitaires. Notre méthode s'appuie sur ces travaux et permet d'analyser et de regrouper des entités similaires. Elle se base sur une analyse objet à l'inverse de la plupart des méthodes précédentes qui considèrent les pixels (Petitjean et al., 2012a).

Le suivi de l'évolution spatio-temporelle d'une zone compte deux étapes : la sélection des objets de références (*RefObjs*) et la construction des *graphes d'évolutions*.

La sélection des *objets de références* est traitée dans (Guttler et al., 2014) comme un problème de recouvrement (Vazirani, 2001). Cette étape considère l'ensemble d'objets complet, étant donné que chaque objet couvre un ensemble de pixels, le but est de sélectionner des objets de telle façon que la grille de pixels soit couverte complètement ou bien au maximum. Sachant qu'un pixel peut être couvert par plusieurs objets car les images sont alignées sur la même grille, les *RefObj* peuvent se chevaucher. Cette contrainte est contournée par l'introduction d'un paramètre  $\alpha$  qui varie entre 0 et 1. Il représente un seuil qui permet de maximiser la couverture et minimiser le chevauchement des *RefObj*.

Ce processus de sélection se fait itérativement, À chaque itération, nous pondérons les objets et nous sélectionnons celui ayant le poids le plus élevé. Ce poids est égal au ratio de la *nouveauté* : nombre de pixel de l'objet non couvert par l'ensemble d'objet de référence déjà sélectionnées, et sa *taille* : nombre de ses pixels.

---

1. [http://www.ecognition.cc/download/baatz\\_schaepe.pdf](http://www.ecognition.cc/download/baatz_schaepe.pdf)

Une fois l'ensemble des *objets de références* sélectionnés, vient l'étape de construction des *graphes d'évolutions*. Un *graphes d'évolution* permet de visualiser l'état de l'objet de référence dans toutes les estampilles temporelles. Chaque *RefObj*, noté  $o^*$ , sera représenté par un ou plusieurs segments dans toutes les images de la série temporelle. L'ensemble de ces segments est ensuite organisé sous forme d'un *graphe d'évolution* retraçant l'évolution spatio-temporelle de l'objet  $o^*$  dans la série d'images.

Formellement, un *graphe d'évolution* est un graphe acyclique orienté DAG (Directed Acyclic Graph), noté  $G_{o^*} = (V_{o^*}, E_{o^*})$ , où  $E_{o^*}$  est l'ensemble des segments qui correspondent à l'objet de référence dans la série d'images, que nous appellerons les nœuds du graphe, et  $V_{o^*}$  l'ensemble des arcs qui relient les différents nœuds. L'ensemble de nœud est sélectionné comme suit :

$$V_{o^*} = \{o | o \in \mathcal{O}, \frac{|Pix(o^*) \cap Pix(o)|}{|Pix(o)|} \geq \sigma_1 \text{ ou } \frac{|Pix(o^*) \cap Pix(o)|}{|Pix(o^*)|} \geq \sigma_2\}$$

Les segments sélectionnés appartiennent à différentes images de la série et doivent satisfaire l'une des deux conditions suivantes : i) au minimum  $\sigma_1\%$  des pixels du segment  $o$  doit être couvert par le *RefObj* ou bien ii) le segment doit recouvrir au minimum  $\sigma_2\%$  des pixels couverts par le *RefObj*.

Une fois l'ensemble de nœud sélectionné, nous définissons l'ensemble des arcs orientés qui structure notre graphe,  $V_{o^*}$ , comme suit :

$$E_{o^*} = \{(o^i, o^j) | o^i \in O_t \cap V_{o^*} \text{ et } o^j \in O_{t+1} \cap V_{o^*} \text{ et } Pix(o^i) \cap Pix(o^j) \neq \emptyset\}$$

Ainsi défini, l'ensemble  $V_{o^*}$  relie uniquement les segments dont les estampilles temporelles se succèdent.

Le graphe résultant décrit l'évolution spatio-temporelle de l'objet de référence. Il est nommé *graphe d'évolution*. Ainsi construit, un *graphe d'évolution* est structuré en couches, chaque couche regroupe les segments d'une seule image de la série, comptant ainsi autant de couches que d'images, organisées en ordre ascendant par estampille temporelle. Une des caractéristiques communes des *graphes d'évolutions* est que la couche comportant l'objet de référence sera uniquement composée de celui-ci.

La figure 2 illustre un exemple de *graphe d'évolution* représentant une zone forestière. Nous remarquons que la structure en couche est explicite et orientée de gauche à droite dans l'axe du temps. Dans cet exemple, notre graphe se compose de six couches issues d'une série temporelle comptant elle aussi six images. Chaque couche reprend les segments représentatifs de l'emprise spatiale de l'objet de référence. Les changements de couleur des segments représentent l'évolution de leur valeurs radiométriques, qui reflète l'évolution du phénomène étudié.

### 3.5 Clustering des graphes d'évolutions

Les méthodes de clustering (Tan et al., 2005) permettent d'analyser les données et de les regrouper dans des groupes (clusters) homogènes. Dans notre cas, le clustering vise à identifier et regrouper les différents types d'évolutions des *objets de références* dans le temps. Ces *ObjRef* sont décrits par un *graphe d'évolution* comme défini en section 3.4. Afin de générer

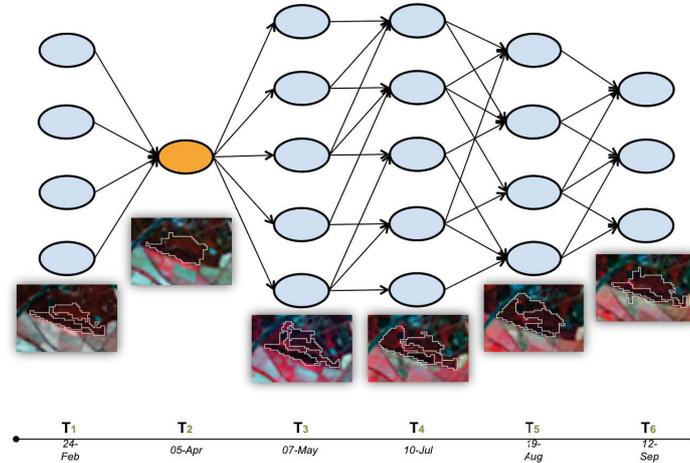


FIG. 2 – Exemple d'un graphe d'évolution représentant une zone forestière.

une représentation exploitable par un algorithme de clustering, nous extrayons l'information contenue dans les *graphes d'évolutions* puis nous générons une représentation synthétique de cette dernière sous forme d'un *synopsis*. Enfin, nous calculons une distance entre chaque paire de *synopsis* pour construire une matrice de distance.

La figure 3 schématise le processus de construction des *synopsis*. Étant donné un graphe d'évolution (Fig. 3(a)), la première phase consiste à extraire tout l'ensemble de ses chemins. Un chemin est défini comme étant une séquence ordonnée de noeuds adjacents, distincts les uns des autres, dont le premier sommet appartient à la première image et le dernier sommet appartient à la dernière image (Fig. 3(b)). Puis, nous agrégeons les valeurs radiométriques des objets appartenant aux différents chemins par image (Fig. 3(c)). Le *synopsis* (Fig. 3(d)) généré est un chemin qui se compose de nouveaux objets créés  $\tilde{O}_t$ .

L'étape d'agrégation calcule une moyenne pondérée des valeurs radiométriques des objets, le poids de chaque objet  $o_t$  appartenant à la couche  $T$  est égale au nombre de chemins dans lequel il apparait. En effet, chaque objet est sommé autant de fois qu'il apparait dans l'ensemble des chemins. Dans l'exemple ci-dessous, considérant la première couche, l'objet  $o_1^1$  appartient à quatre chemins distincts, tandis que l'objet  $o_2^1$  n'appartient qu'à deux chemins. De ce fait, nous pouvons conclure que l'objet  $o_1^1$  est plus important que l'objet  $o_2^1$ . Ainsi un poids de quatre est attribué au premier objet tandis qu'un poids de deux est associé au deuxième objet. Au final, à l'objet créé  $\tilde{O}_1$ , est associé un vecteur de valeurs radiométriques ( $Info(\tilde{O}_1)$ ) résultat de l'agrégation pondérée des deux derniers objet.

Ainsi, les *graphes d'évolutions* sont transformés en *synopsis*. Chaque paire de *synopsis* permettra d'évaluer la distance entre leur *graphe d'évolution* respectif. Étant donnés deux *graphes d'évolutions*  $G_1$  et  $G_2$ , nous construisons leur deux *synopsis* respectifs  $syn_1$  et  $syn_2$ , puis leur distance est calculée selon les équations 1 et 2 :

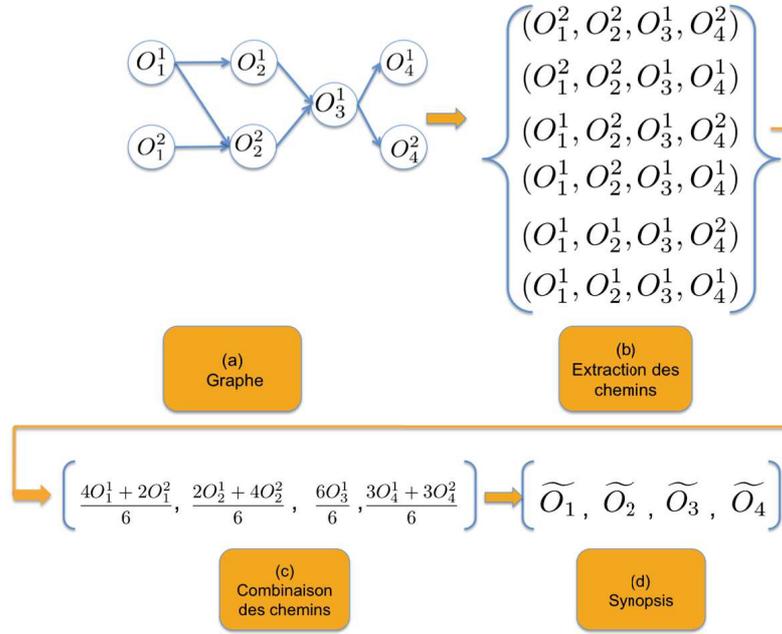


FIG. 3 – Schéma des étapes de transformation d'un graphe d'évolution en synopsis.

$$dist_s(syn_1, syn_2) = \frac{\sum_{t=1}^{|syn_1|} dist(syn_1[t], syn_2[t])}{|syn_1|} \quad (1)$$

$$dist(\tilde{O}_j, \tilde{O}_i) = \|\text{Info}(\tilde{O}_j) - \text{Info}(\tilde{O}_i)\|_2 \quad (2)$$

L'équation 1 permet de calculer la distance entre les deux synopsis,  $syn_1$  et  $syn_2$ , en sommant la distance entre leurs objets.

Les *synopsis* possèdent le même nombre d'objets ( $T$ ), un objet par estampille temporelle. Pour chaque estampille temporelle, nous évaluons la distance entre les deux objets des *synopsis* en calculant la distance euclidienne entre leurs valeurs radiométriques ( $\text{Info}(\cdot)$ ) comme indiqué dans l'équation 2. Enfin, nous sommes les distances euclidiennes calculées pour tous les objets pour obtenir la distance finale entre les deux *synopsis* comme l'indique l'équation 1.

Une fois toutes les distances calculées, nous construisons une matrice de distance afin de pouvoir appliquer les différents algorithmes de clustering indépendamment des données initiales traitées (Tan et al., 2005) (tels que le clustering hiérarchique, Kernel K-Means, le clustering spectral ou le clustering basé sur la densité, etc.).

## 4 Données

La zone d'étude est constituée d'une série temporelle de 6 images satellitaires Landsat-5 (acquises entre février et septembre 2009) décrivant la vallée de *Libron* située dans le sud de la France. Le site est principalement caractérisé par des parcelles agricoles (céréales et vignobles) et des espaces naturels (parcelles de forêt et de garrigue). La superficie couverte est d'environ 1 655 ha.

Seuls les pixels à l'intérieur des limites de la zone d'étude sont utilisés pour les segmentations (18 394 pixels pour chaque image). En considérant l'ensemble des images satellites, l'étape de segmentation produit, au total, 1 218 segments.

## 5 Expérimentations

Dans cette section, nous allons évaluer notre méthode d'une manière quantitative mais aussi qualitative. L'évolution quantitative est réalisée en calculant l'un des indices de validité du clustering les plus utilisés dans la littérature. Tandis que l'évaluation qualitative est réalisée par un expert en télédétection. Avant de présenter nos résultats, nous commençons par décrire le cadre d'évaluation.

### 5.1 Contexte expérimental

Une fois les *objets de références* sélectionnés, ils sont fournis à l'expert qui procède à leur classification. Comme résultat, nous avons obtenu 9 classes représentant différents types d'occupations du sol (i.e. céréale, vigne, forêt, etc.). Afin d'évaluer notre méthode, nous avons comparé les clusters obtenus aux classes identifiées précédemment par l'expert.

Comme décrit dans la section 3.4, le processus est paramétré selon trois paramètres :  $\alpha$ ,  $\sigma_1$  et  $\sigma_2$ . En vue de fixer les valeurs les plus adéquates pour ces paramètres, nous les avons fait varier sur différents intervalles. Entre autre, nous avons fait varier  $\alpha$  dans l'intervalle [0.3, 0.9], quand aux paramètres  $\sigma_1$  et  $\sigma_2$ , ils varient dans l'intervalle [0.2, 0.5]. Puis, nous avons rapporté la couverture et le chevauchement des *graphes d'évolutions* ainsi que les *objets de références*. Nous avons sélectionné, selon les recommandations des experts, les valeurs 0,4, 0,2 et 0,25 respectivement. Cette procédure a généré 112 *graphes d'évolutions*.

Afin de situer notre méthode par rapport à l'état de l'art, nous nous sommes comparés à trois approches. La première repose sur les *objets de références*, la seconde sur les pixels et enfin la troisième combine l'information portée par le pixel et l'objet associé :

i) la première approche permet une analyse par objet, ainsi nous procédons au clustering des *objets de références*, notée *RObject-Based Clustering*. ii) le clustering basé pixel, noté (*Pixel-Based Clustering*), associe à chaque pixel un vecteur de valeurs radiométriques, sachant que les images de notre série sont alignées sur la même grille, on reprends les valeurs radiométriques du pixel dans chaque image ordonnées selon leur estampille temporelle. iii) La méthode introduite par (Petitjean et al., 2012b) propose d'enrichir l'information radiométrique du pixel avec celle de l'objet auquel il appartient. Pour chaque estampille temporelle, nous concaténons l'information radiométrique portée par le pixel à celle portée par son objet. Puis nous ordonnons les  $T$  ( $T$  étant la taille de la série temporelle d'images) vecteurs résultats en ordre croissant suivant les estampilles temporelles, notée *Pixel-Object-Based Clustering*.

Notre approche, notée *EGraphClustering* (**E**volution **G**raph-based **C**lustering), est comparée à un clustering à deux niveaux de granularité pixel et objet. Le clustering du premier niveau regroupe les deux approches : *Pixel-Based Clustering* et *Pixel-Object-Based Clustering* et démontre l'importance de prendre en compte la dimension spatiale des données. Quand au clustering de deuxième niveau, il concerne l'approche *RObject-Based Clustering* et démontre la nécessité de prendre en compte la structure des *graphes d'évolutions*.

En ce qui concerne les algorithmes de clustering, nous avons sélectionné l'algorithme hiérarchique qui supporte les différents approches à comparer. Le nombre de clusters dans notre cas d'étude a été fixé à 9, ce qui est égal au nombre de classes identifiées par l'expert.

Afin d'évaluer la qualité du clustering, nous utilisons la mesure d'Information Mutuelle Normalisée (NMI : Normalized Mutual Informatio) (Ienco et al., 2012). Nous avons aussi évalué l'efficacité des différentes méthodes par rapport aux temps d'exécution.

## 5.2 Évaluation quantitative

La table 1 reprend les valeurs de la NMI pour les différentes approches. Nous remarquons que l'approche par *objet de référence* (*RObject-Based Clustering*) obtient la valeur minimale. La dimension temporelle permet une meilleur discrimination des différentes classes d'occupations du sol.

La comparaison entre *EGraphClustering*, *Pixel-Based Clustering* et *Pixel-Object-Based Clustering*, montre que notre méthode fournit le résultat le plus proche de la classification de l'expert, en exploitant efficacement les deux dimension temporelle et spatiale.

La table 2 reprend les temps d'exécution des différentes méthodes. Le processus a été décomposé en quatre étapes. Elles consistent principalement à calculer la matrice de distance (Dist. comp.) et le clustering (Clustering), deux autre étapes en été prises en considération à savoir la construction des *graphes d'évolutions* (Graph const.) et la construction du *synopsis* (Synopsis constr.) pour notre approche.

Les résultats obtenus montrent clairement un déphasage de temps d'exécution. L'approche *EGraphClustering* requière moins d'une seconde pour donner les résultats finaux alors que l'approche *Pixel-Based Clustering* a besoin de plus de 7000 secondes vu le nombre d'entités à clusteriser. L'approche *RObject-Based Clustering* compte moins d'une seconde de temps d'exécution, cependant elle est la moins performante en terme de NMI car elle ne prend pas en compte la dimension temporelle des données. Nous soulignons aussi que le temps nécessaire à la construction des *graphes d'évolutions* et les *synopsis* est de moins d'une seconde. Ces résultats démontrent que notre méthode peut supporter le passage à l'échelle.

	<b>Hiérarchique</b>
<i>EGraphClustering</i>	0.38
<i>RObject-Based Clustering</i>	0.26
<i>Pixel-Based Clustering</i>	0.26
<i>Pixel-Object-Based Clustering</i>	0.34

TAB. 1 – Valeurs de la NMI pour les différentes approches pour appliquées sur la vallée du libron.

	Graph extr.	Synopsis constr.	Dist. comp.	Clustering
<i>EGraphClustering</i>	0.6	0.2	0.2	0.003
<i>RObject-Based Clustering</i>	-	-	0.04	0.001
<i>Pixel-Based Clustering</i>	-	-	5 893.98	2 469.53
<i>Pixel-Object-Based Clustering</i>	-	-	11 309.16	2 363.42

TAB. 2 – Temps d'exécution des différentes approches pour la vallée du libron.

### 5.3 Évaluation quantitative

Afin d'évaluer qualitativement nos résultats, nous avons procédé à une analyse manuelle des clusters. Les résultats sont illustrés dans la figure 4. Cette figure schématise quatre graphes d'évolutions. Les deux graphes d'en haut (Fig. 4(a) et Fig. 4(b)) appartiennent au même cluster, *vignes*, tandis que les deux graphes du bas (Fig. 4(c) et Fig. 4(d)) appartiennent à un autre cluster, *sclérophylle*. Ces clusters sont nommés par l'expert selon leur type d'occupation.

Considérons d'abord les deux premiers graphes qui appartiennent au cluster des *vignes* (Fig. 4(a) et Fig. 4(b)), nous pouvons remarquer que d'un point de vue radiométrique, les deux graphes évoluent pareillement. Le début de la série ( $T_1$  and  $T_2$ ) ainsi que sa fin ( $T_5$  et  $T_6$ ) sont caractérisés par la stabilité radiométrique des deux graphes. Tandis qu'au milieu de la série ( $T_3$  et  $T_4$ ), nous notons un changement brusque de leur radiométrie.

Contrairement au premier cluster, l'inspection des deux graphes appartenant au cluster des *sclérophylle* (Fig. 4(c) et Fig. 4(d)) met en évidence une évolution complètement différente. Dans ce cas de figure, la réponse spectrale des deux graphes reste stable tout au long de la série temporelle, ceci est rattaché à la nature de ce type de végétation. En effet, les forêts *sclérophylle* poussent lentement et la série temporelle couvre une période de huit mois ce qui est une période courte pour la dynamique liée à ce type de phénomènes.

## 6 Conclusion

Dans cet article, nous avons présenté l'approche *EGraphClustering* qui permet d'analyser des entités spatio-temporelles à partir de STIS considérant des objets au lieu de pixels comme unité élémentaire d'analyse. Nous avons évalué la méthode *EGraphClustering* sur une série temporelle réelle composée de six images satellitaires et nous avons démontré que notre approche est plus performante que les approches standard basées sur les pixels en tenant compte à la fois de la qualité du clustering et du temps de calcul. Comme travaux futurs, nous prévoyons de poursuivre nos travaux selon deux axes : (i) analyse d'un autre jeu de données et (ii) utilisation d'un autre algorithme de clustering (algorithme de clustering spectrale) afin de souligner l'indépendance de la méthode au type d'algorithme choisi.

## 7 Remerciements

Ces travaux ont été réalisés dans le cadre du projet (CNES, Dynamitof 2016 TOSCA) et soutenu par le ministère algérien de l'enseignement supérieur et IRSTEA.

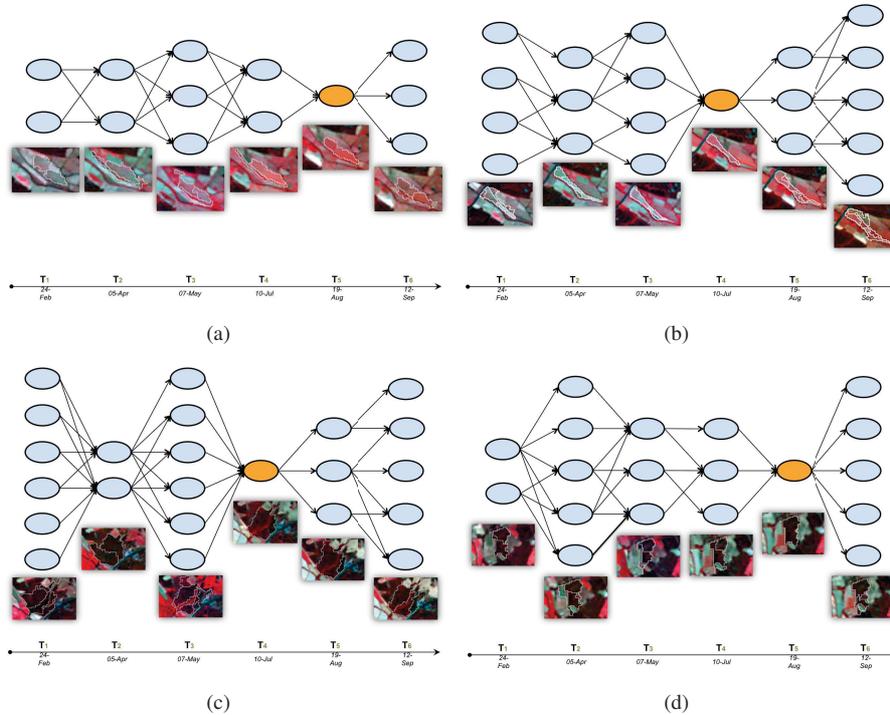


FIG. 4 – Exemples de graphes d'évolution : deux graphes appartenant aux cluster des vignes (a), (b) et deux graphes appartenant au cluster de la végétation chlorophylle (c), (d) de la vallée du libron.

## Références

- Batista, G. E. A. P. A., E. J. Keogh, O. M. Tataw, et V. M. A. de Souza (2014). CID : an efficient complexity-invariant distance for time series. *Data Min. Knowl. Discov.* 28(3), 634–669.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65(1), 2–16.
- Guttler, F., S. Alleaume, C. Corbane, D. Ienco, J. Nin, P. Poncelet, et M. Teisseire (2014). Exploring high repetitivity remote sensing time series for mapping and monitoring natural habitats - A new approach combining OBIA and k-partite graphs. In *IGARSS*.
- Ienco, D., R. G. Pensa, et R. Meo (2012). From context to distance : Learning dissimilarity for categorical data clustering. *TKDD* 6(1), 1.
- Jr, J. R., R. Haas, J. Schell, et D. Deering (1974). Monitoring vegetation systems in the great plains with erts. *NASA special publication 351*, 309.
- Lillesand, T., R. Kiefer, et J. Chipman (2008). Remote sensing and image interpretation.
- Nativi, S., P. Mazzetti, M. Santoro, F. Papeschi, M. Craglia, et O. Ochiai (2015). Big data challenges in building the global earth observation system of systems. *Environmental Modelling*

*and Software* 68, 1–26.

- Petitjean, F., J. Inglada, et P. Gançarski (2012a). Satellite image time series analysis under time warping. *IEEE Trans. Geos. and Rem. Sensing* 50(8), 3081–3095.
- Petitjean, F., C. Kurtz, N. Passat, et P. Gançarski (2012b). Spatio-temporal reasoning for the classification of satellite image time series. *Pattern Recognition Letters* 33(13), 1805–1815.
- Qin, Y., Z. Niu, F. Chen, B. Li, et Y. Ban (2013). Object-based land cover change detection for cross-sensor images. *International Journal of Remote Sensing* 34(19), 6723–6737.
- Rakthanmanon, T., B. J. L. Campana, A. Mueen, G. E. A. P. A. Batista, M. B. Westover, Q. Zhu, J. Zakaria, et E. J. Keogh (2013). Addressing big data time series : Mining trillions of time series subsequences under dynamic time warping. *TKDD* 7(3), 10.
- Rakthanmanon, T., E. J. Keogh, S. Lonardi, et S. Evans (2012). Mdl-based time series clustering. *Knowl. Inf. Syst.* 33(2), 371–399.
- Tan, P.-N., M. Steinbach, et V. Kumar (2005). *Introduction to Data Mining, (First Edition)*. Boston, MA, USA : Addison-Wesley Longman Publishing Co., Inc.
- Vazirani, V. V. (2001). *Approximation Algorithms*. New York, NY, USA : Springer-Verlag New York, Inc.
- Zhang, N., Y. Hong, Q. Qin, L. Liu, N. Zhang, Y. Hong, Q. Qin, et L. Liu (2013). VsdI : a visible and shortwave infrared drought index for monitoring soil and vegetation moisture based on optical remote sensing. *International Journal of Remote Sensing* 34, 4585–4609.
- Zhu, Q., G. E. A. P. A. Batista, T. Rakthanmanon, et E. J. Keogh (2012). A novel approximation to dynamic time warping allows anytime clustering of massive time series datasets. In *SDM*, pp. 999–1010.

## Summary

Nowadays, satellite technologies provide huge amounts of remote sensing images. Such sources of information describe geographical areas through time, producing time series of satellite images. A remote sensing time series usually contains spatio-temporal phenomena that are difficult to understand and monitor due to their intrinsic complexity. In this work, we propose a new clustering framework to mine time series of satellite images. Our proposal firstly detects spatio-temporal entities, secondly it characterises their evolutions by a graph-based representation and finally it produces clusters of spatio-temporal entities sharing similar evolution behaviours. Our approach is original in that it works at object-level (image segments) and not pixel-level as is usually the case in the remote sensing field. We experimentally validate our framework on a real world time series of satellite images w.r.t standard techniques employed in remote sensing analysis. We also highlight how the obtained results can be easily interpreted by domain experts.