

MÉTHODES PROBABILISTES D'APPRENTISSAGE PROFOND A PRIORI PHYSIQUES DE REPRÉSENTATIONS INTERPRÉTABLES

Journées CNES des Jeunes Chercheurs 2022

Y. ZERAH^{1,2}, J. INGLADA², S. VALERO²

¹ Université Fédérale Toulouse Midi-Pyrénées

² CESBIO, Université de Toulouse, CNES/CNRS/INRAe/IRD/UPS

Observation de la Terre et données massives

Depuis quelques années, la mise en service de satellites d'observation de la Terre avec des délais de revisite courts et des résolutions spatiales améliorées, a conduit à la production d'une quantité importante d'images de télédétection, avec des données de natures très diverses (optique, radar, lidar, etc...).

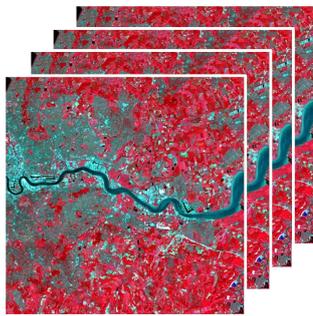


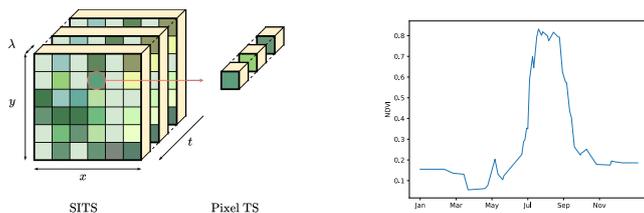
Figure 1: Série Temporelle d'Images Satellite

En particulier, les satellites Sentinel-2 du programme Copernicus, font l'acquisition de *séries temporelles d'images satellites*, à grande résolution spatiale (10m), spectrale (12 bandes), et temporelle (revisite tous les 5 jours). Cependant, l'extraction d'information utile d'une telle donnée n'est pas directe. Il s'agit d'une donnée massive, complexe, avec une grande variabilité spatiale. Il y a un besoin de produire des **représentations réduites** qui capturent les aspects importants de ces données. Enfin, il est difficile et coûteux d'obtenir des données de terrain de référence, ce qui suppose des approches **non supervisées**. Durant cette thèse nous proposons de développer des méthodes permettant l'apprentissage non supervisé de représentations de séries temporelles d'images satellites. En particulier, nous intégrons des connaissances physiques au processus d'apprentissage afin de rendre les représentations apprises interprétables.

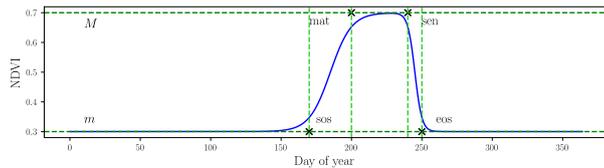
En particulier, nous intégrons des connaissances physiques au processus d'apprentissage afin de rendre les représentations apprises interprétables.

Modèle phénologique de série temporelles de NDVI

L'indice NDVI (Normalized Difference Vegetation Index) caractérise la vigueur et l'activité de la végétation photosynthétique : $NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \in [-1, 1]$



Les séries temporelles de NDVI issues de pixel de végétation ont un cycle saisonnier modélisable par une fonction simple.



Variable	Description
M	Maximum de la double-sigmoïde
m	Minimum de la double-sigmoïde
sos	Start Of Season, début de la croissance
mat	Maturity, fin de la croissance
sen	Senescence, début du déclin
eos	End Of Season, fin du déclin

$$f_{\phi}(t) = (M - m) (S_1(t) - S_2(t)) + m$$

avec :

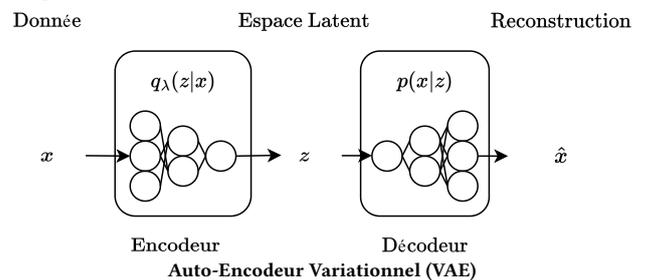
$$S_1(t) = \left(1 + \exp\left(2 \frac{\text{sos} + \text{mat} - 2t}{\text{mat} - \text{sos}}\right) \right)^{-1}$$

$$S_2(t) = \left(1 + \exp\left(2 \frac{\text{sen} + \text{eos} - 2t}{\text{eos} - \text{sen}}\right) \right)^{-1}$$

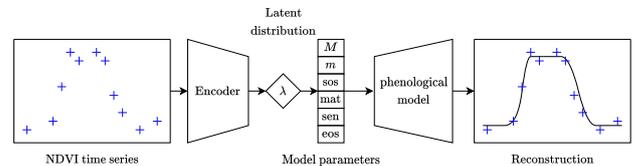
Avec ce modèle phénologique, il est aussi possible de **simuler** des séries temporelles, pour générer des données de validation.

Apprentissage avec a priori physique avec des VAE

Un **auto-encodeur variationnel** est un type de **modèle génératif** composé d'un encodeur et d'un décodeur, tous deux des **réseau de neurones**. Toute donnée d'entrée est encodée comme un **variable aléatoire**, dont les réalisations sont décodées pour reconstruire la donnée d'entrée.



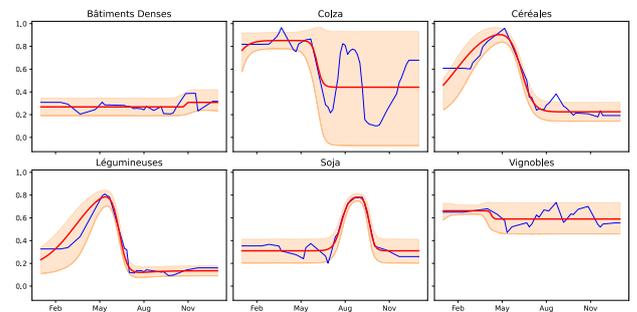
Afin de rendre l'**espace latent** interprétable, nous intégrons des connaissances physiques concernant la donnée encodée, afin de guider l'apprentissage. En particulier, nous remplaçons le réseau de neurones du décodeur par un **modèle paramétrique connu** de la donnée. Alors les variables latentes sont **sémantiquement liées** aux paramètres du modèle.



Dans pheno-VAE, Nous utilisons le modèle phénologique comme décodeur.

Résultats: pheno-VAE

Nous utilisons le modèle double sigmoïde dans un VAE pour encoder des séries temporelles de NDVI par ses **paramètres phénologiques**. Pheno-VAE est entraîné sur 10^6 séries temporelles Sentinel-2 de la région Toulousaine.



Reconstructions de séries temporelles de NDVI Sentinel-2.

Les reconstructions de séries temporelles de NDVI avec pheno-VAE sont cohérentes. L'erreur est minimale lorsque la série temporelle est bien décrite par le modèle phénologique, sinon en compensation, la variance des reconstructions augmente.

Travaux en cours

Perspectives:

- Encodage temporel permettant de s'affranchir d'artefact de reconstructions.
- Utilisation de la méthode avec un modèle de transfert radiatif prenant en compte l'ensemble des composantes spectrales des images Sentinel-2.