

Rehaussements ont pour but l'amélioration de l'aspect visuel d'une image pour faciliter son interprétation.

Image non-spectrale = image dont l'information affectée à chaque pixel est déduite des luminances spectrales pour caractériser des propriétés des objets observés (**variables thématiques**).

- Indices (végétation, chlorophylle, eau libre...)
- Transformation en composantes principales pour compression / interprétation.
- Classification (supervisée ou non)

Indices

Les données de télédétection de la surface de la Terre sont abondantes et à l'échelle planétaire, mais ne sont pas directement pertinentes.

Connaissant les propriétés de la surface (végétation, sol, eau), il est possible de définir des **indices** pour :

- Caractériser le type de surface ;
- De manière normalisée pour faciliter les comparaisons ;
- En minimisant l'influence des facteurs externes (illumination, inclinaison...)

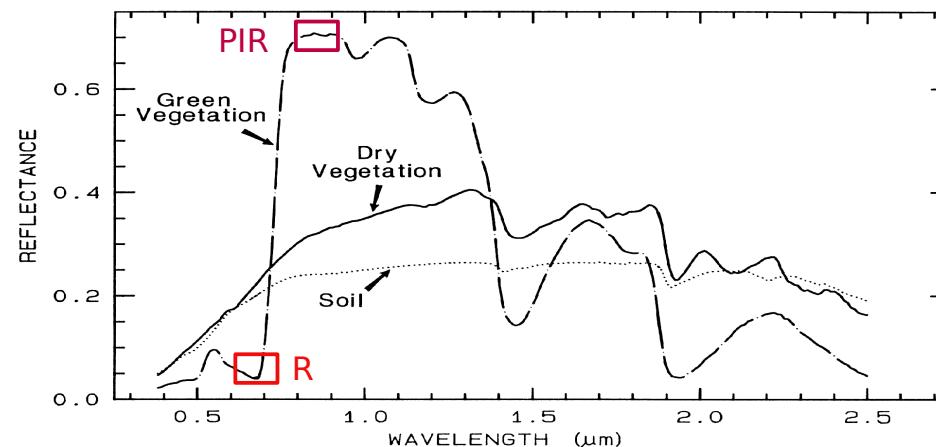
Ces indices ont d'abord été développés pour caractériser la végétation, puis d'autres types de surface (NDWI → eau libre, NDSI → neige, NBR → zone brûlée...).

Plus de détails : <https://www.nature.com/articles/s41597-023-02096-0>

Exemple d'indice de végétation : **Normalized Difference Vegetation Index (NDVI)** :

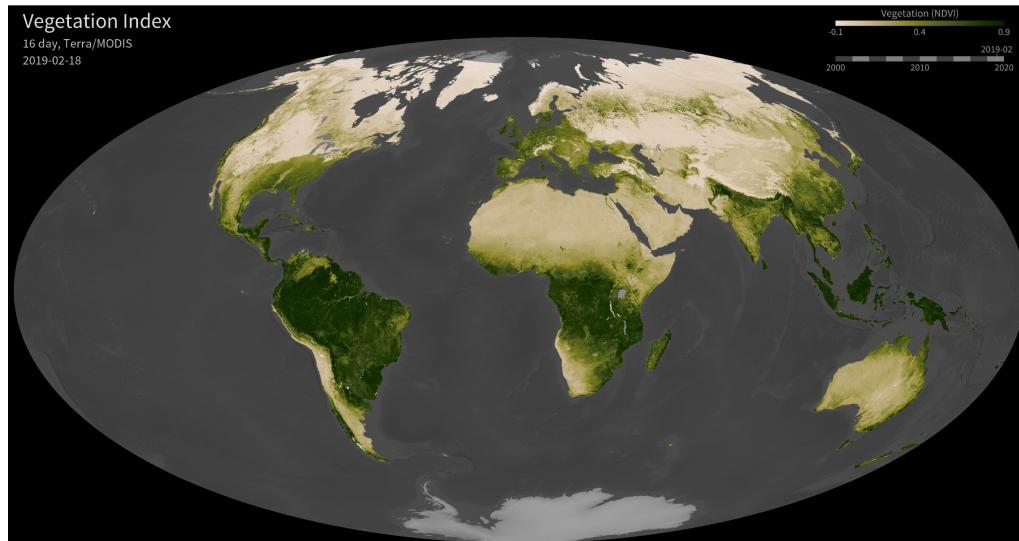
$$\text{NDVI} = (\text{PIR} - \text{R}) / (\text{PIR} + \text{R}) \quad -1 \text{ (-0.5)} < \text{NDVI} < +1 \text{ (+0.5)}$$

- Permet la comparaison de la couverture végétale en relative indépendance du relief.
- Indice sans compensation → sensible aux effets atmosphériques.
- Relation exponentielle avec densité végétation verte.
- Adapté aux couverts végétaux peu denses et “sature” pour couverts végétaux denses.

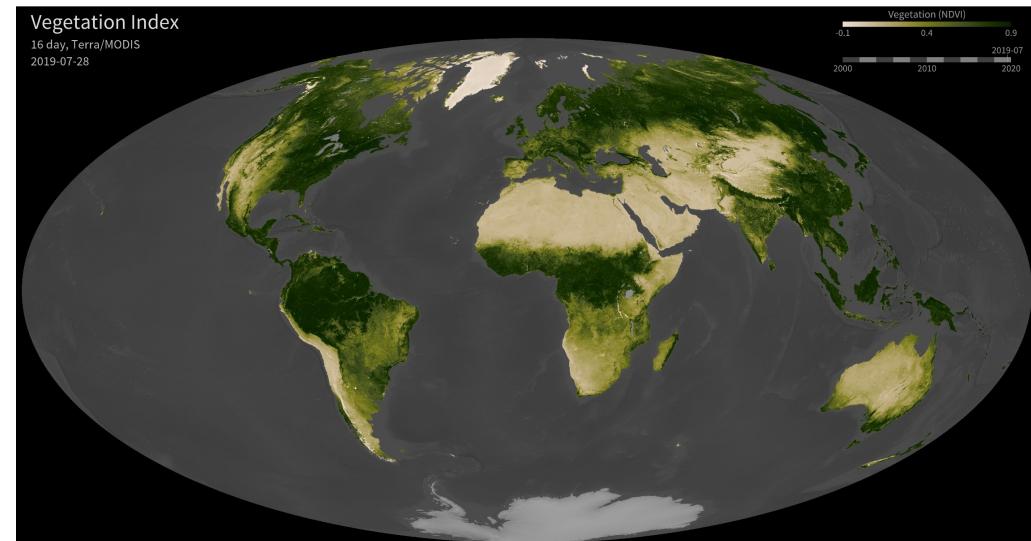


Ex : NDVI global from TERRA/MODIS

Février 2019



Juillet 2019

NEO/NASA/Goddard Space Flight Center <https://svs.gsfc.nasa.gov/31053/>

Applications dans l'agriculture de précision

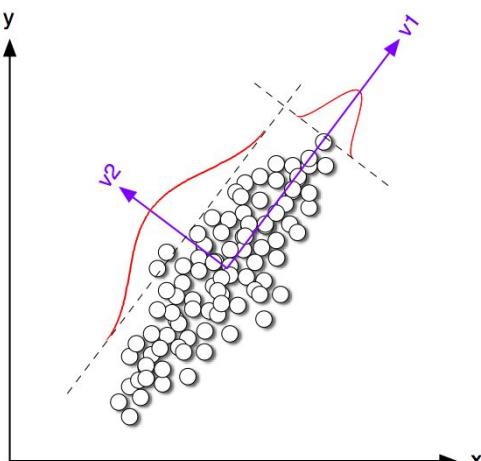
<https://www.eetindia.co.in/the-sensors-that-enable-precision-agriculture/>



Transformation orthogonale : transformation en composantes principales

Repose sur l'**analyse en composantes principales** : changement de système tel que les nouvelles variables soient non-corrélées entre elles. Chaque axe devient porteur du maximum d'information.

Directions des nouveaux axes sont données par les **variances maximales** des luminances observées, dans l'espace des diff. bandes spectrales disponibles.



Calcul des CP :

identifier base orthonormée /
matrice de covariance est
diagonale.

= calculer valeurs propres de
la matrice de covariance

Hypothèses pour optimalité ACP :

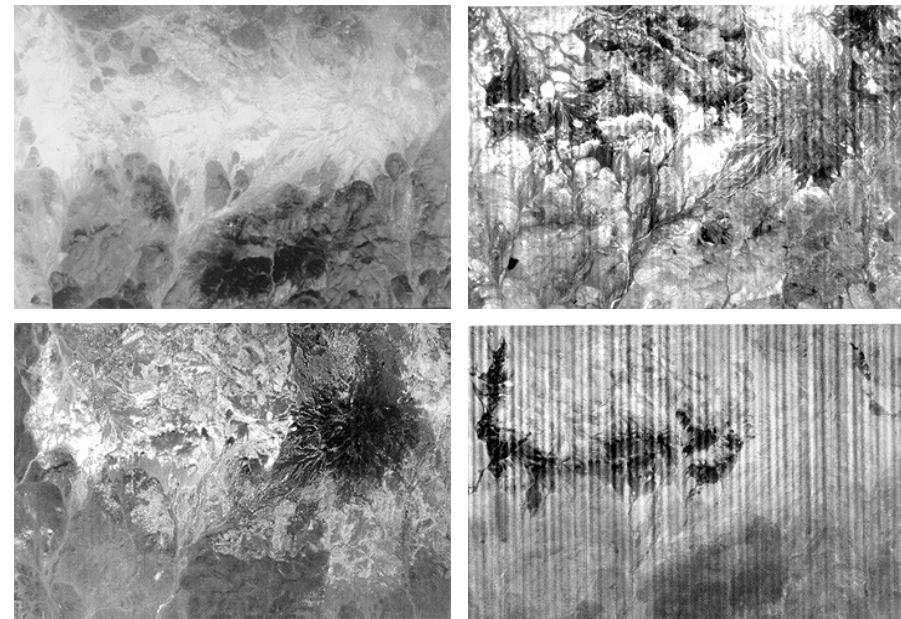
- Linéarité (comb. lin. des variables)
- Grandes variances contiennent de l'info
- Les composantes principales sont \perp

Application de la TCP à une image de télédétection

Compression : les 3 premières composantes principales d'une **image TM Landsat** contiennent en général de 95 à 96% de l'information → gain de ~50% en terme de stockage.

Rehaussement : réduction du bruit car il est contenu de manière croissante dans les composantes principales de rang croissant.

Ex : image Landsat 4 TM, Utah
Identification structures géol.



Classification d'image

Principe : transposer dans une approche numérique les modalités de l'interprétation "humaine" des images de télédétection, pour automatiser cette analyse.

Classification = regroupement de pixels selon leur ressemblance spectrale ou selon des unités spatiales interprétables.

3 approches :

- **Approche pixel** : pixel est l'élément de référence. Regroupement uniquement en fonction de la ressemblance spectrale.
- **Approche zonale** : portion d'image définie par fenêtre d'auscultation (idem filtres spatiaux). La détection des contours exploite forts gradients aux changements de zones.
- **Approche objet** : identification d'objets par analyse morphologique. Nécessite haute résolution...

Classification non-supervisée

Aucune information externe à l'image n'est disponible. Le regroupement des pixels repose uniquement sur la ressemblance spectrale.

Classification ascendante hiérarchique

Au départ : autant de classes que de pixels. Puis on agrège les 2 pixels les + proches (distance spectrale). On calcule alors distance entre le centre de gravité de la classe créée et les autres pixels, et ainsi de suite jusqu'au nombre de classes souhaité.

Simple mais nombreux calculs...

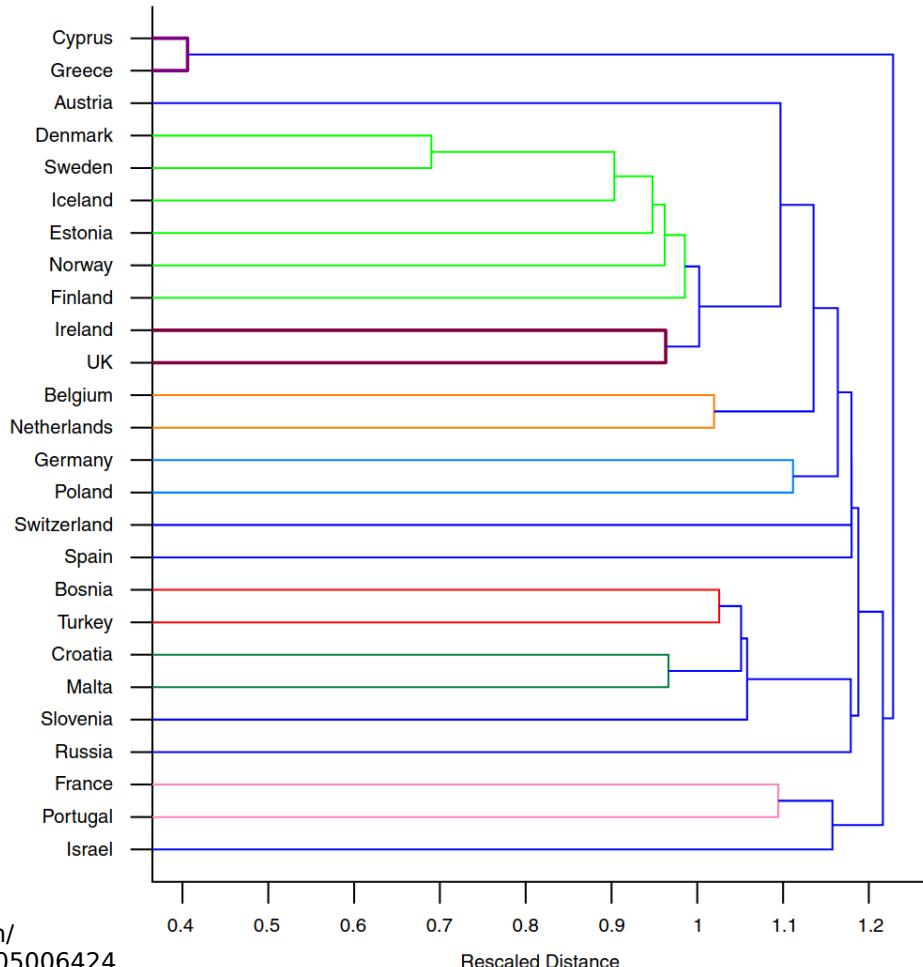
Classification séquentielle

On fixe le nombre de classes et on définit pixels de départ (tirage aléatoire ou non) et distance de fusion. Puis on agrège les pixels situés à une distance $<$ distance de fusion. On itère alors jusqu'à avoir couvert toute l'image.

Ex de classification non-dirigée : votes lors de l'eurovision...

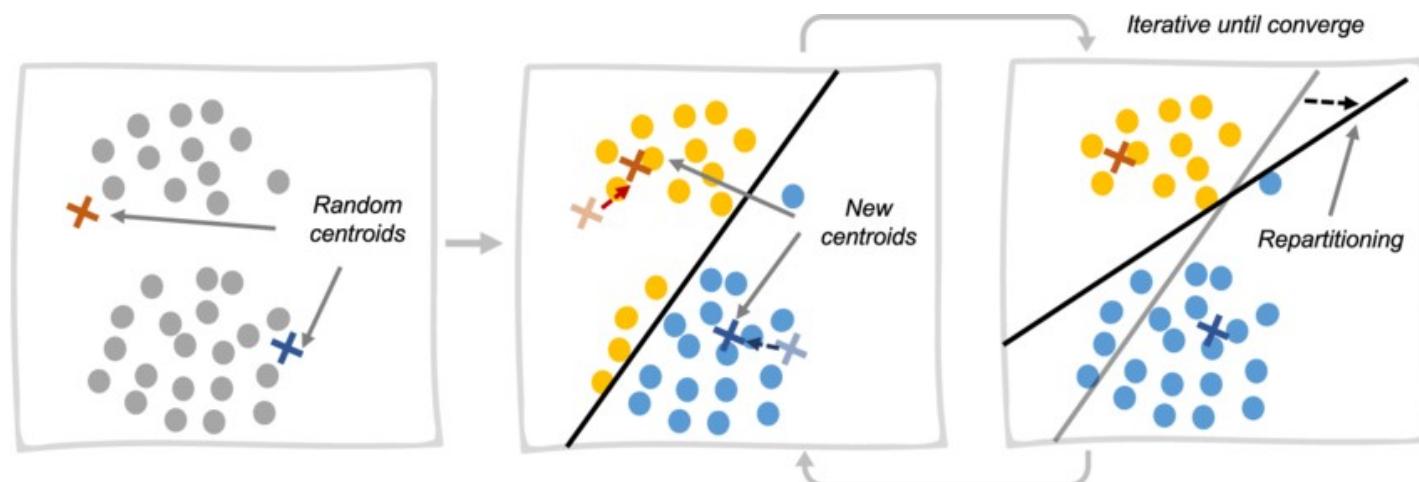
Tiré d'une étude menée à l'université d'Oxford :

As a measure of each country's actions, we form a data series consisting of the average number of points assigned to each other entrant in the years in which they both compete. The closeness of each pair of countries can then be measured by comparing these data series using Pearson's correlation coefficient (ρ). The Pearson coefficients are then rescaled to produce a 'distance' between 0 and 2 using the relationship that the rescaled distance is equal to $\text{Sqrt}(2(1 - \rho))$. The most closely related countries have rescaled distances close to 0, while the least correlated countries have distances close to 2. This data is then used to plot a dendrogram which provides a visual aid for identifying clusters.



K-means

1. On définit a priori un nombre de “clusters” (K)
2. Tirage aléatoire de K centroïdes
3. On regroupe dans le même cluster les points les plus proches (L_2) de chaque centroïde
4. On calcule un nouveau centroïde minimisant la variance intra-cluster
5. On itère jusqu’au critère de convergence (changement centroïdes, nb itérations...)



Input: distance matrix D & number of clusters k

(Cao et al, 2023)

Classification supervisée

Si on dispose d'informations a priori sur la classification dans la zone d'étude, il est possible d'utiliser ces données de référence pour entraîner le modèle de classification.

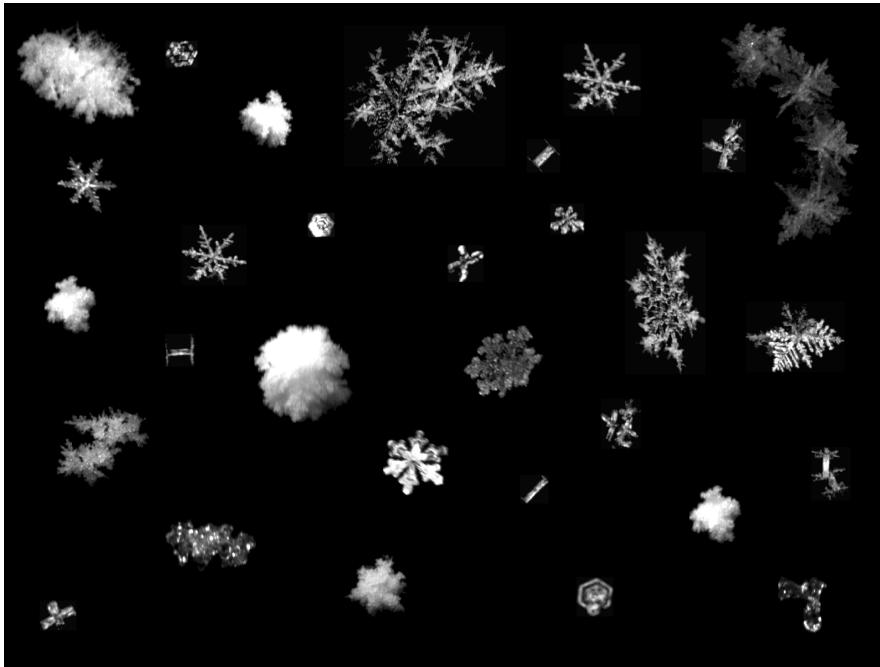
Mais il faut “vérifier” la qualité de cet apprentissage. On procède en divisant en 3 le jeu de données de référence : **jeu d'apprentissage ou d'entraînement, jeu de validation et jeu de test**, qui servent à entraîner, valider et vérifier les résultats du classificateur.

Ensuite, le modèle peut être appliquer à l'ensemble de l'image ou des images similaires.

Par cette approche, on introduit des éléments de connaissances et d'expertise externes à l'information contenue dans l'image.

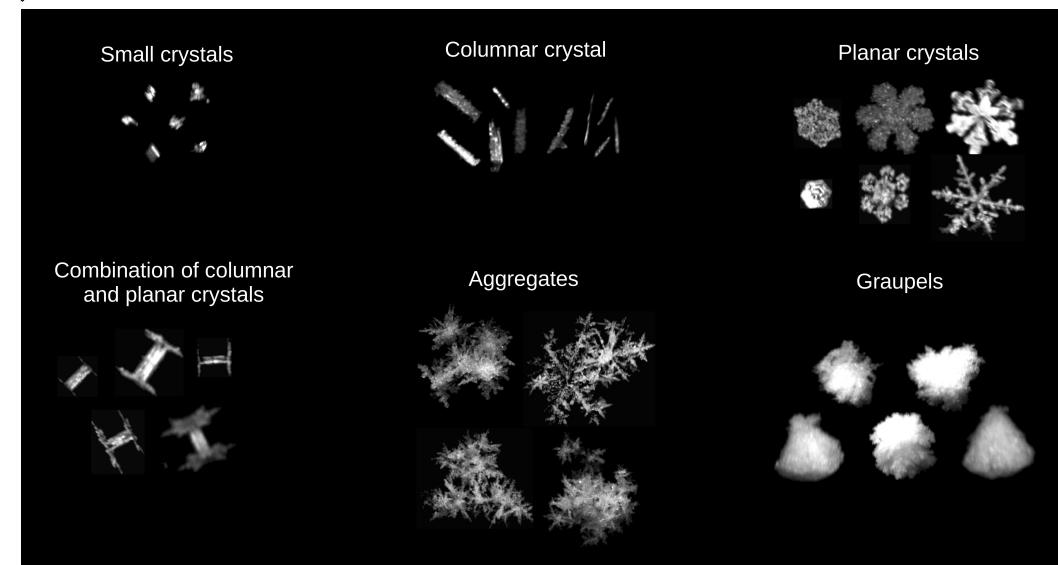
Lien avec l'apprentissage automatique (machine learning): random forest, CNN, GAN...

Ex de classification dirigée : flocons de neige...



Jeu d'entraînement/test de 3500 images
(manuellement classifiées)

Régression logistique multinomiale



Questions

1. Pourquoi l'indice NDVI est plus couramment utilisé que l'indice LAI pour décrire la végétation ?
2. Pourquoi l'ACP permet de faire de la compression de données ?
3. Quelle est la principale différence entre la classification dirigée et non-dirigée ?

1. Transformations radiométriques

- a) Rehaussement : nécessité de corriger les valeurs de luminance si problème de fonctionnement ou transmission du capteur, pour retrouver ce que le capteur aurait dû mesurer.
- b) Transformations radiométriques : correction des valeurs de luminance mesurées des effets liés au capteur (fonctionnement non-parfait, ex : dérive) et à l'environnement (pente, ombrage, atmosphère).

2. Transformation géométriques : rendre comparables/combinables diff. images

- a) Géoréférencement.
- b) Calcul des luminances correspondantes dans le nouveau référentiel.

Approche globale (+ rapide mais - précise) ou locale (orthoimage, nécessite MNT mais + précise)

3. Rehaussement : modifications de l'image pour améliorer sa qualité visuelle

- a) Approche globale : anamorphose d'histogramme, transformée de Fourier
- b) Approche locale : filtres spatiaux (linéaires ou statistiques), transformée en ondelettes

4. Extraction d'information : mesure indirecte → variable d'intérêt

Indices (végétation, etc), transformations orthogonales (ACP)
Classification (supervisée ou non), apprentissage automatique plus généralement