

# Apprentissage de dynamique temporelle pour le démixage de séquences d'images hyperspectrales



**Mots-clés:** télédétection, imagerie hyperspectrale, systèmes dynamiques, apprentissage, deep learning, ResNets.

## Contexte

La télédétection est un domaine qui consiste en l'observation d'un phénomène physique d'intérêt à distance, par opposition à une observation *in situ*. En particulier, l'imagerie satellitaire permet de cartographier l'occupation des sols pour des applications variées, allant de l'agriculture de précision au suivi environnemental, en passant par la planification urbaine. L'identification automatique des matériaux présents dans la scène observée ainsi que l'estimation de leurs proportions dans toute l'image est un problème central pour ces applications. Cependant, des images en niveau de gris ou couleur classiques sont souvent insuffisantes pour discriminer les matériaux d'intérêt (par exemple différentes espèces de végétation). On utilise donc des modalités d'imagerie non conventionnelles que sont l'imagerie multispectrale et hyperspectrale [1]. Ces images consistent en l'acquisition d'information dans de nombreuses longueurs d'ondes du domaine visible ou infrarouge proche (et pas seulement dans le rouge, vert et bleu comme en imagerie couleur classique), comme illustré par la figure 1a. La connaissance d'un spectre de réflectance pour chaque pixel de l'image, par opposition à un simple triplet de valeurs pour les images couleur, permet une caractérisation bien plus précise des matériaux constituant la scène imagée, d'où le fort intérêt de ces images pour les problématiques d'imagerie satellitaire (et de plus en plus en imagerie médicale également).

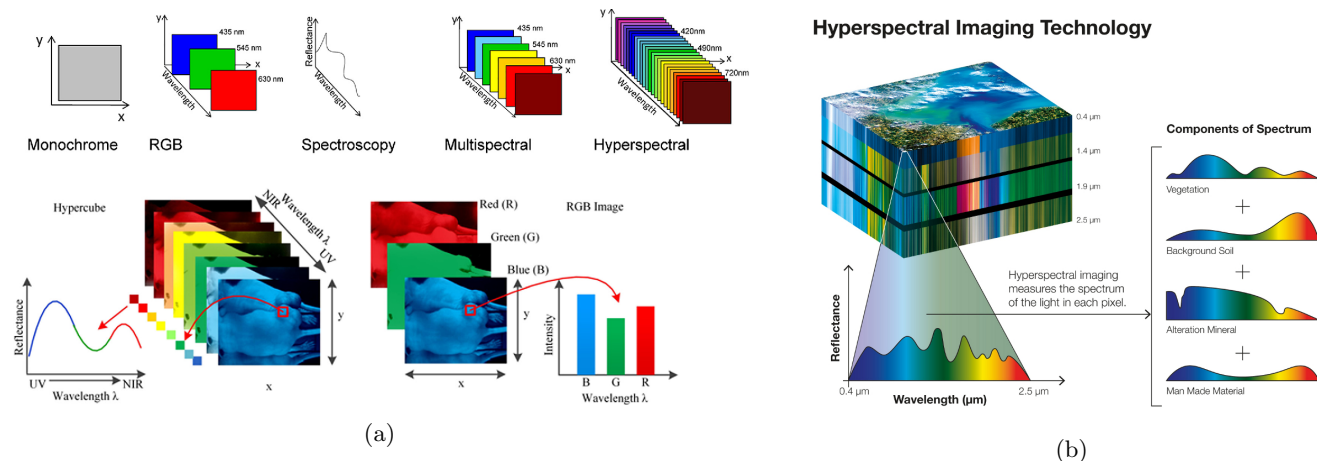


Figure 1: Illustration (a) du principe d'imagerie hyperspectrale (vs. imagerie couleur) et (b) du problème des pixels mixtes et du démixage spectral.

En revanche, la résolution spectrale accrue se fait au détriment de la résolution spatiale. La réponse d'un pixel au sol est très fréquemment un mélange de plusieurs réponses de constituants purs (par exemple la végétation, la terre nue, le bitume, le béton, etc), comme le présente la figure 1b. Le problème inverse chargé de l'identification des constituants purs (appelés *endmembers*) et de leurs proportions relatives (appelés *abondances fractionnelles*) au sein de chaque pixel s'appelle le démixage spectral. Les différentes hypothèses simplificatrices posées pour la résolution du problème de démixage (mélange linéaire ou non, présence de pixels purs dans l'image ou non, etc) ont conduit

à un vaste panel d’algorithmes [2].

Les capteurs modernes permettent désormais d’avoir accès à des séries temporelles de ces images hyperspectrales, permettant de suivre l’évolution des quantités d’intérêt au cours du temps. Néanmoins, l’information temporelle est souvent ignorée lors du traitement de ces séries temporelles, où les images sont souvent traitées individuellement [3] en ce qui concerne la problématique de démixage spectral. De plus, de nombreux obstacles tels que la couverture nuageuse, les problèmes de recalage des images ou d’échantillonnage irrégulier freinent les développements dans ce domaine.

## Objectif

L’objectif de ce stage est d’utiliser des méthodes d’apprentissage à base de réseaux de neurones/deep learning [4] pour prendre en compte cette information temporelle dans la problématique du démixage, en se basant sur une modélisation du problème par un modèle de type espace-état:

$$\frac{ds_{p,t}}{dt} = \mathcal{F}(s_{p,t}) + \eta_t \quad (1)$$

$$\mathbf{X}_t = \mathcal{H}_A(\mathbf{S}_t) + \epsilon_t \quad (2)$$

Ces modèles permettent de définir les quantités d’intérêt (ici par exemple, les signatures spectrales des matériaux  $s_{p,t}$ ,  $p$  étant l’indice du matériau considéré, et  $t$  l’indice temporel) dont on souhaite suivre l’évolution, un modèle dynamique de cette évolution (Eq. (1)) sous la forme d’une équation différentielle ou d’une équation aux dérivées partielles, et un modèle d’observation donnant la relation entre ces variables (regroupées dans la matrice  $\mathbf{S}_t$ ) et les données  $\mathbf{X}_t$  observées au niveau du capteur à chaque pas de temps (Eq. (2)). En particulier, on s’attachera à apprendre le modèle dynamique  $\mathcal{F}$  depuis les données plutôt que de le prescrire *a priori*. Cela permettra ensuite d’interpoler les données entre les échantillons temporels, voire idéalement de prédire l’évolution de la scène dans le futur.

Pour ce faire, il a été montré récemment que des architectures de réseaux de neurones particulièrement adaptées à l’apprentissage de systèmes dynamiques existent, même avec un échantillonnage temporel irrégulier [5, 6]. Outre les réseaux récurrents classiques tels que les LSTM, le potentiel des réseaux résiduels (ResNets) [7] a été mis en évidence sur plusieurs applications en télédétection, notamment pour le suivi de dynamiques océaniques ou encore la prise en compte de la variation d’illumination au cours du temps en imagerie hyperspectrale. Des exemples de telles architectures sont présentés en figure 2. Un LSTM (figure 2a) est un réseau récurrent qui permet de gérer les corrélations temporelles à long terme. Les ResNets (figure 2b) sont particulièrement adaptés à l’apprentissage de modèles dynamiques car ils mettent en oeuvre un schéma d’intégration d’Euler du type  $s_{t+1} = s_t + h\mathcal{F}(s_t)$ , où  $\mathcal{F}$  est l’opérateur dynamique à apprendre.




Figure 2: Apprentissage de modèles dynamiques sur une trajectoire de signatures spectrales  $s_t$  via (a) un LSTM et (b) Un ResNet.  $L$  est la dimensions des signatures spectrales considérées.

Différentes méthodes et architectures seront testées pour répondre à ce problème, et selon l’avancée du stage, le candidat pourra en proposer de nouvelles pour gérer des cas plus complexes que ceux déjà traités. Le candidat travaillera sur des jeux de données satellitaires multi et hyperspectraux réels pré-traités concernant des zones variées

telles que la pointe bretonne ou la région de Fukushima, au Japon. Il devra de plus concevoir des jeux de données simulés pour effectuer une preuve de concept sur des cas d'étude ciblés.

## Candidat

Le candidat doit posséder de solides bases en traitement du signal et de l'image, apprentissage automatique/deep learning. Compétences requises:

- Apprentissage automatique, traitement du signal et des images, mathématiques appliquées
- Programmation en Python (numpy, scipy, matplotlib...)
- Experience dans les méthodes de deep learning et les bibliothèques associées en Python (Keras, Tensorflow, Pytorch)
- Intérêt pour l'imagerie satellitaire

Le stage sera basé au LRDE (Laboratoire de Recherche et Développement de l'EPITA, <https://www.lrde.epita.fr/wiki/Home>), au Kremlin-Bicêtre, près de Paris. Des visites à Brest ou à Grenoble au cours du stage pourront être envisagées.

## Contact et candidature

Les encadrants du stage sont :

- Guillaume Tochon, Maître de conférences, EPITA, LRDE, Le Kremlin-Bicêtre, France.
- Lucas Drumetz, Maître de conférences, IMT-Atlantique, Lab-STICC, Brest, France.

Sont également impliqués sur le projet :

- Mauro Dalla Mura, Maître de conférences, Grenoble-INP, GIPSA-lab, Grenoble, France.
- Ronan Fablet, Professeur, IMT-Atlantique, Lab-STICC, Brest, France.

L'équipe encadrante possède une grande expérience du traitement d'images satellite et des méthodes d'intelligence artificielle appliquées à ces problématiques.

**Rémunération** 1000€brut/mois

**Début du stage** À partir de mi-février

**Durée du stage** 5/6 mois

Merci d'envoyer votre candidature (CV, lettre de motivation, relevé de notes du M1/2<sup>e</sup> année de cycle ingénieur + descriptif du M2/3<sup>e</sup> année de cycle ingénieur) à [guillaume.tochon@lrde.epita.fr](mailto:guillaume.tochon@lrde.epita.fr) et [lucas.drumetz@imt-atlantique.fr](mailto:lucas.drumetz@imt-atlantique.fr).

## References

- [1] J. M. Bioucas-Dias, A. Plaza, G. Camps-Valls, P. Scheunders, N. Nasrabadi, and J. Chanussot, "Hyperspectral remote sensing data analysis and future challenges," *IEEE Geoscience and remote sensing magazine*, vol. 1, no. 2, pp. 6–36, 2013.
- [2] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, "Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches," *IEEE journal of selected topics in applied earth observations and remote sensing*, vol. 5, no. 2, pp. 354–379, 2012.
- [3] M. A. Goenaga, M. C. Torres-Madronero, M. Velez-Reyes, S. J. Van Bloem, and J. D. Chinea, "Unmixing analysis of a time series of hyperion images over the guánica dry forest in puerto rico," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 6, no. 2, pp. 329–338, 2012.
- [4] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, p. 436, 2015.
- [5] R. Fablet, S. Ouala, and C. Herzet, "Bilinear residual neural network for the identification and forecasting of dynamical systems," *arXiv preprint arXiv:1712.07003*, 2017.
- [6] D. Nguyen, S. Ouala, L. Drumetz, and R. Fablet, "Em-like learning chaotic dynamics from noisy and partial observations," *arXiv preprint arXiv:1903.10335*, 2019.
- [7] F. Rousseau, L. Drumetz, and R. Fablet, "Residual networks as flows of diffeomorphisms," *Journal of Mathematical Imaging and Vision*, pp. 1–11, 2019.