

Projet ANR ASTRAL: Apprentissage statistique pour l'imagerie SAR multi-dimensionnelle

Recrutement post-doctorat de 18 mois:

Modèles génératifs et apprentissage de représentation
pour l'imagerie radar à synthèse d'ouverture

1 Contexte

L'imagerie radar à synthèse d'ouverture est une modalité d'imagerie active, pouvant fonctionner de jour comme de nuit, même en présence de couverture nuageuse. A la différence de l'imagerie optique, la gamme de longueurs d'ondes utilisées en imagerie radar (du centimètre au mètre) ne correspond pas à un rayonnement visible mais aux ondes radio. Les images radar permettent de distinguer les surfaces lisses (rivières, lacs, routes) de celles qui sont rugueuses à l'échelle de la longueur d'onde (herbe, végétation basse, arbres). Les structures artificielles (bâtiments, véhicules, pylônes électriques, etc..) renvoient de forts échos qui se traduisent par des structures très brillantes dans les images radar. L'imagerie radar est donc une technique très complémentaire de l'imagerie optique, présentant de nombreuses spécificités.

La figure ci-dessous présente deux images de la même zone, acquise à gauche par un système radar aéroporté et à droite par un imageur optique. Bien que représentant la même scène, ces deux images sont très différentes. Pour pouvoir réaliser l'analyse des images radar, il est donc nécessaire de développer des traitements spécifiques.





image radar polarimétrique
représentation de Pauli: (HH - VV, 2HV, HH + VV)

image optique correspondante


Un des traitements spécifiques à l'imagerie radar est la réduction du chatoiement (bruit qui apparaît sur les images radar). Des progrès spectaculaires ont été réalisés récemment par nos équipes en combinant des techniques d'apprentissage profond et une stratégie d'entraînement auto-supervisée [Dalsasso et al., 2021]:



Les images radar (ici, acquises par le satellite TerraSAR-X) peuvent être fortement améliorées par un réseau profond.

2 Objectifs

Les modèles génératifs d'images offrent un cadre très riche dans les contextes de restauration et d'interprétation des images. Ils peuvent par exemple donner accès à une caractérisation des incertitudes plus informative qu'une simple variance pixel-à-pixel [Sankaranarayanan et al., 2022], conduire potentiellement à des représentations invariantes à des modifications de l'acquisition (incidence, bande de fréquence) et donner accès à des stratégies de fusion multi-modalité (optique-radar).



Représentation sémantiquement informative des incertitudes dans un problème de restauration d'images (source: [Sankaranarayanan et al., 2022]).

De nombreux modèles génératifs ont été proposés ces dernières années en imagerie optique [Bond-Taylor et al., 2021], basés par exemple sur des GAN [Goodfellow et al., 2014, Karras et al., 2021], des réseaux inversibles [Rezende and Mohamed, 2015] ou encore des modèles de diffusion [Ho et al., 2020, Dhariwal and Nichol, 2021]. L'apprentissage non supervisé de représentation, avec des stratégies de type masquage [He et al., 2022] ou de *contrastive learning* [Chen et al., 2020], est

particulièrement puissant pour obtenir des représentations compactes des images pouvant servir dans de nombreuses tâches aval faiblement supervisées (ex: classification, détection d’objet).

L’objectif de ce sujet de post-doc sera de développer des modèles de scènes radar dans un cadre auto-supervisé, puis d’exploiter ces modèles pour différentes tâches (restauration, segmentation sémantique, détection de changement, fusion multi-modalité).

3 Cadre de travail

Ce post-doc s’inscrit dans le projet ANR ASTRAL qui rassemble des équipes de Télécom Paris, de l’Université de Saint-Etienne, du Cnam et de l’ONERA afin de développer des approches d’apprentissage statistique en imagerie radar (<https://astral.wp.imt.fr/>).

La localisation du post-doc est principalement à Saint-Etienne, au laboratoire Hubert Curien. Le travail sera réalisé en étroite collaboration avec les équipes de Télécom Paris et du Cnam dans lesquelles un séjour pour réaliser une partie du travail est envisageable.

Le laboratoire Hubert Curien de l’Université de Saint-Etienne est une UMR CNRS de 230 personnes composée de deux départements: Informatique, sécurité, image et Optique, photonique, surfaces. Le laboratoire est internationalement reconnu, notamment pour son activité en machine learning et en problèmes inverses. L’équipe d’encadrement est formée de

- Loïc Denis, Professeur
(<https://perso.univ-st-etienne.fr/deniloic/>)
- Rémy Emonet, Maître de Conférences
(<https://home.heeere.com/>)
- Amaury Habrard, Professeur, Membre Senior de l’IUF
(<https://perso.univ-st-etienne.fr/habrarda/>)
- Damien Muselet, Maître de Conférences
(<https://perso.univ-st-etienne.fr/muda8804/>)

Les candidatures sont à envoyer à Loïc Denis (loic.denis@univ-st-etienne.fr) sous la forme d’un CV, d’une courte lettre de motivation, d’une liste de publications et des coordonnées de 3 personnes référentes. Une nationalité d’un pays de l’Union Européenne est requise.

Références

- [Bond-Taylor et al., 2021] Bond-Taylor, S., Leach, A., Long, Y., and Willcocks, C. G. (2021). Deep generative modelling: A comparative review of vaes, gans, normalizing flows, energy-based and autoregressive models. *IEEE transactions on pattern analysis and machine intelligence*.
- [Chen et al., 2020] Chen, T., Kornblith, S., Norouzi, M., and Hinton, G. (2020). A simple framework for contrastive learning of visual representations. In *International conference on machine learning*, pages 1597–1607. PMLR.
- [Dalsasso et al., 2021] Dalsasso, E., Denis, L., and Tupin, F. (2021). As if by magic: self-supervised training of deep despeckling networks with merlin. *IEEE Transactions on Geoscience and Remote Sensing*, 60:1–13.
- [Dhariwal and Nichol, 2021] Dhariwal, P. and Nichol, A. (2021). Diffusion models beat gans on image synthesis. *Advances in Neural Information Processing Systems*, 34:8780–8794.
- [Goodfellow et al., 2014] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27.

-
- [He et al., 2022] He, K., Chen, X., Xie, S., Li, Y., Dollár, P., and Girshick, R. (2022). Masked autoencoders are scalable vision learners. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 16000–16009.
- [Ho et al., 2020] Ho, J., Jain, A., and Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 33:6840–6851.
- [Karras et al., 2021] Karras, T., Aittala, M., Laine, S., Härkönen, E., Hellsten, J., Lehtinen, J., and Aila, T. (2021). Alias-free generative adversarial networks. *Advances in Neural Information Processing Systems*, 34:852–863.
- [Rezende and Mohamed, 2015] Rezende, D. and Mohamed, S. (2015). Variational inference with normalizing flows. In *International conference on machine learning*, pages 1530–1538. PMLR.
- [Sankaranarayanan et al., 2022] Sankaranarayanan, S., Angelopoulos, A. N., Bates, S., Romano, Y., and Isola, P. (2022). Semantic uncertainty intervals for disentangled latent spaces. In *Advances in Neural Information Processing Systems*.