

Stage M2 – Apprentissage de *prior* pour les problèmes inverses

English version below

Problématique – Problèmes inverses, *machine learning*, grandes dimensions, reconstruction d’images, signal–image.

Outils – DNN, réseaux inversibles, régularisation, optimisation.

Applications – L’équipe travaille sur des problèmes de microscopie, radioastronomie, imagerie hyperspectrale... Le choix se fera en concertation avec l’étudiant.

Contact et lieu – F. Orieux (francois.orieux@universite-paris-saclay.fr, 01 75 31 70 55), Laboratoire L2S. C. Soussen, Laboratoire L2S.

Contexte

Le traitement de mesures instrumentales nécessite souvent d’utiliser le modèle de données, ou modèle direct¹, dans la méthode. Par exemple les mesures sont affectées d’un bruit, d’un flou, ou vivent dans un autre espace que celui des inconnues (des coefficients de Fourier *versus* une image pour le cas de l’IRM).

Autant le modèle direct est stable et bien posé (à partir des paramètres on peut générer des données), autant le problème inverse est le plus souvent instable et mal-posé [1], comme illustré en figure 1b où le résultat n'est pas satisfaisant.

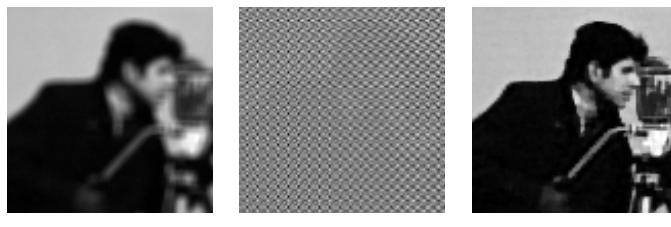


FIGURE 1 – Exemple de problème inverse (mal posé) : le *deblurring* ou déconvolution. L’image 1b est une reconstruction naïve sans régularisation.

Travail mené – méthodologie

Les techniques de résolution de problèmes inverses ont fortement évolué ces dernières années avec les nouvelles techniques d’apprentissage machine. On peut mentionner

le déroulage d’algorithmes itératif (*unrolling*) [2], les approches *plug-and-play*, le RED (*regularization by denoising*), ou encore les *a priori* basé données.

Le travail consistera à comprendre et mettre en œuvre les approches utilisant les réseaux génératifs comme les VAE ou encore les réseaux inversibles, par exemple celui proposé dans [3]². Il s’agit d’une approche reposant sur la minimisation d’un critère mixte

$$J(x) = \|y - Hx\|_2^2 + R(x)$$

où le terme d’attache aux données utilise le modèle d’observation connu H (flou, inpainting, debruitage...) et le terme de régularisation $R(x)$ est appris à partir de données. La solution est alors définie comme

$$\hat{x} = \arg \min_x J(x).$$

- Dans un premier temps, le stagiaire se familiarisera sur les problèmes inverses et leurs méthodes de résolution.
- Ensuite, il devra faire un état de l’art sur les méthodes basées données et apprentissage statistique pour la résolution de problèmes inverses. Le sujet étant récent, la littérature est abondante et diverse. Des points d’entrée bibliographique seront fournis.
- Nous nous attacherons à mettre en œuvre une des deux méthodes mentionnées plus haut. Les résultats devront être comparés aux résultats obtenus avec les approches classiques : filtre de Wiener, parcimonie ... pour lesquels des codes sont à disposition.
- L’application sera à déterminer parmi celles de l’équipe : synthèse de Fourier pour la radioastronomie, la microscopie ou encore reconstruction d’image en tomographie.

Le travail se fera sur un poste équipé d’une carte GPU Nvidia 3080 ou 4090 avec Linux, TensorFlow et Python.

Profil – compétences acquises

L’étudiant devra avoir une formation type ingénieur ou Master 2 en traitement du signal ou d’images, *data science* ou *machine learning*. Il devra posséder des connaissances en mathématiques appliquées ou en programmation.

L’étudiant acquerra au cours du stage des compétences en estimation, optimisation, apprentissage machine, inférence statistique, traitement de données et python.

1. ou encore modèle d’acquisition

2. <https://arxiv.org/abs/2101.08661>

M2 internship – Learning prior for inverse problems

Problematic – Inverse problems, *machine learning*, large dimensions, image reconstruction, signal-image.

Tools – DNN, invertible networks, regularization, optimization.

Applications – The team works on problems involving microscopy, radio astronomy, hyperspectral imaging, etc.

Contact and loc. – F. Orieux (francois.orieux@universite-paris-saclay.fr, 01 75 31 70 55), L2S laboratory. C. Souassen, L2S.

Context

Processing instrumental measurements often requires the use of a data model, or direct model³, in the method. For example, measurements are affected by noise, blur, or live in a space other than that of the unknowns (like Fourier coefficients for MRI).

While the direct model is stable and well-posed, and data can be generated from the parameters, the inverse problem is more often unstable and ill-posed [1], as illustrated in figure 1b where the result is unsatisfactory.

Work conducted – methodology

Inverse problem-solving techniques have greatly evolved in recent years with new machine learning techniques. These include *unrolling* of iterative algorithms [2], plug-and-play approaches, RED (*regularization by denoising*), and data-based *priors*. The main objective is usually to exploit image databases to improve regularization.

The work will mainly involve implementing approaches using generative networks such as VAEs or invertible networks, for example the one proposed in [3]⁴. This approach is based on the minimization of a mixed criterion

$$J(x) = \|y - Hx\|_2^2 + R(x)$$

where the data attachment terms makes use of a known observation model H (blur, inpainting, addition of noise...) and the regularization term $R(x)$ is learned from data. The solution is then defined as

$$\hat{x} = \arg \min_x J(x).$$

- Initially, the student will become familiar with inverse problems and their resolution methods.
- Next, he or she will review the state of the art in data-driven and machine-learning methods for solving inverse problems. As this is a recent topic, the literature is abundant and diverse. Bibliographic inputs will be provided.
- We will focus on implementing one of the two methods mentioned above. The results will be compared with those obtained using conventional approaches : Wiener filter, sparsity... for which codes are available.

— The application will be among those of the team and to be determined : Fourier synthesis for radioastronomy, microscopy or tomographic imaging.

Work will be carried out on a workstation equipped with a Nvidia 3080 or 4090 GPU card, Linux, TensorFlow and Python.

Candidate profile – acquired skills

The student should have an engineering or Master 2 degree in signal or image processing, *data science* or *machine learning*. Knowledge of applied mathematics or programming skills will be appreciated.

During the course of the internship, the student will acquire skills in estimation, optimization, machine learning, statistical inference, data processing and Python.

Références

- [1] J. IDIER, « Convex Half-Quadratic Criteria and Interacting Auxiliary Variables for Image Restoration, » *IEEE Trans. on Image Process.*, t. 10, n° 7, p. 1001-1009, juill. 2001.
- [2] D. GILTON, G. ONGIE et R. WILLETT, « Deep Equilibrium Architectures for Inverse Problems in Imaging, » *IEEE Transactions on Computational Imaging*, t. 7, p. 1123-1133, 2021.
- [3] T. OBERLIN et M. VERM, « Regularization via Deep Generative Models : An Analysis Point of View, » in *2021 IEEE International Conference on Image Processing (ICIP)*, sept. 2021, p. 404-408.

3. or acquisition model

4. <https://arxiv.org/abs/2101.08661>