

Modèles génératifs pour les problèmes inverses de Poisson avec application à l'imagerie d'émission

Projet de recherche en Master, CREATIS, Lyon, France

Keywords Imagerie médicale, Modèles génératifs, Optimisation

Supervision:

- Thibaut MODRZYK, PhD student, INSA Lyon, TomoRadio group, CREATIS Laboratory
 - Voichita MAXIM, full professor, INSA Lyon, TomoRadio group, CREATIS Laboratory
-

Contexte L'imagerie d'émission repose sur la détection de photons issues de désintégrations radioactives. Les deux modalités principales en imagerie d'émission sont la tomographie par émission de positons, et la tomographie par émission monophotonique, *Positron Emission Tomography* (PET) et *Single Photon Emission Computed Tomography* (SPECT) en anglais. De part le processus d'acquisition, les données brutes sont des sinogrammes corrompus par du bruit de Poisson. La reconstruction d'une image à partir de ces sinogrammes se modélise alors comme un problème inverse linéaire:

$$y \sim \mathcal{P}(Ax) \quad (1)$$

où \mathcal{P} est une distribution de Poisson. L'objectif est alors de retrouver l'image x à partir de mesures y , connaissant l'opérateur de reconstruction A .

Un algorithme particulièrement répandu en imagerie d'émission est l'algorithme *Maximum Likelihood Expectation Maximization* (MLEM) [Shepp and Vardi, 1982], dont les variantes sont aujourd'hui implémentées dans les scanners commerciaux. Cet algorithme, lorsqu'il est appliqué à des données bruitées, va avoir tendance à amplifier le bruit des mesures, produisant des artefacts dans les images reconstruites. Une stratégie fréquente est alors de régulariser l'algorithme en imposant des propriétés *a priori* sur les reconstructions. Parmi ces régularisations, on peut notamment citer la régularisation de type variation totale, *Total Variation* (TV) en anglais [Maxim et al., 2023].

Ces dernières années, les réseaux de neurones sont de plus en plus intégrés au processus de reconstruction car ils permettent de reconstruire des images de bien meilleure qualité que les régularisations "à la main" [Zhang et al., 2022]. Encore plus récemment, les modèles génératifs tels que les modèles de diffusion [Song et al., 2021] ou de flow matching [Lipman et al., 2023] se sont imposés comme des candidats très prometteurs pour servir d'*a priori* pour les problèmes inverses [Chung et al., 2023], grâce à leur capacité à modéliser des distributions d'images complexes. Leur utilisation reste toutefois délicate : ces modèles peuvent générer des hallucinations ou des structures absentes des données, ce qui est critique en imagerie médicale. Dans le cas des problèmes inverses de Poisson, leur application directe reste encore très peu explorée. Le stage aura pour objectif principal l'intégration de ces modèles génératifs au processus de reconstruction [Webber et al., 2025].

Plan de travail Afin de mener à bien l'objectif du stage, l'étudiant devra

- se familiariser avec l'algorithme MLEM utilisé pour la reconstruction en imagerie d'émission
- se familiariser avec les modèles génératifs
- se familiariser avec la famille d'algorithmes dits *Plug-and-Play*
- adapter un algorithme Plug-and-Play pour bruit de Poisson [Modrzyk et al., 2025] aux modèles de diffusions
- réaliser des tests préliminaires sur images naturelles, en utilisant des modèles de diffusion pré-entraînés
- transférer ces résultats sur données d'émissions simulées
- possiblement étendre la méthode aux modèles de flow matching

Profil du candidat Le candidat devra être à l'aise avec la programmation en Python et la bibliothèque PyTorch. Une bonne maîtrise des bases du deep learning et de l'entraînement de modèles est attendue. Enfin, le candidat aura une appétence pour la physique et les mathématiques appliquées, au cœur de ce projet.

References

- [Chung et al., 2023] Chung, H., Kim, J., Mccann, M. T., Klasky, M. L., and Ye, J. C. (2023). Diffusion posterior sampling for general noisy inverse problems. In *ICLR*.
- [Lipman et al., 2023] Lipman, Y., Chen, R. T. Q., Ben-Hamu, H., Nickel, M., and Le, M. (2023). Flow Matching for Generative Modeling. arXiv:2210.02747.
- [Maxim et al., 2023] Maxim, V., Feng, Y., Banjak, H., and Bretin, E. (2023). Tomographic reconstruction from Poisson distributed data: a fast and convergent EM-TV dual approach. *Numerical Algorithms*, 94(2):701–731.
- [Modrzyk et al., 2025] Modrzyk, T., Etxebeste, A., Bretin, E., and Maxim, V. (2025). A convergent Plug-and-Play Majorization-Minimization algorithm for Poisson inverse problems.
- [Shepp and Vardi, 1982] Shepp, L. A. and Vardi, Y. (1982). Maximum likelihood reconstruction for emission tomography. *IEEE transactions on medical imaging*, 1(2):113–122. Publisher: IEEE.
- [Song et al., 2021] Song, Y., Sohl-Dickstein, J., Kingma, D. P., Kumar, A., Ermon, S., and Poole, B. (2021). Score-based generative modeling through stochastic differential equations. In *ICLR*.
- [Webber et al., 2025] Webber, G., Mizuno, Y., Howes, O. D., Hammers, A., King, A. P., and Reader, A. J. (2025). Likelihood-Scheduled Score-Based Generative Modeling for Fully 3D PET Image Reconstruction. *IEEE transactions on medical imaging*. Publisher: IEEE.
- [Zhang et al., 2022] Zhang, K., Li, Y., Zuo, W., Zhang, L., Van Gool, L., and Timofte, R. (2022). Plug-and-Play Image Restoration With Deep Denoiser Prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(10):6360–6376.