

Romain Vo^{1,2}, Julie Escoda¹, Caroline Vienne¹, Adrien Stolidi¹, Étienne Decencière²

¹Université Paris-Saclay, CEA, List, F-91190, Palaiseau, France

²Mines Paris, PSL University, Centre for mathematical morphology (CMM), 77300 Fontainebleau, France

romain.vo@cea.fr



Enjeux de la Tomographie RX industrielle

- ▶ Outil d'évaluation non destructive puissant pour le contrôle qualité des pièces mais **coûteux en temps d'acquisition** car des milliers de radiographies sont nécessaires pour reconstruire l'objet en 3D
- ▶ Approches par apprentissage généralement limitées à la reconstruction de tranches 2D [1] et **mal adaptées pour gérer des volumes 3D fortement résolus**
- ▶ **Objectif** : développer une méthode de reconstruction pour objets 3D permettant de *réduire le nombre de mesures* et par conséquent le temps d'acquisition tout en conservant une *bonne qualité de reconstruction* et un *coût mémoire raisonnable*.

Principe

Le problème de reconstruction tomographique est un problème inverse, qui consiste à retrouver l'objet $f^\dagger \in \mathbb{R}^n$ à partir de mesures $b \in \mathbb{R}^m$ telles que:

$$b = Af^\dagger + \epsilon, \quad m \ll n$$

L'approche standard consiste à calculer une estimation de **Maximum a posteriori**:

$$\hat{f} = \arg \min_{f \in \mathbb{R}^n} \mathcal{L}(f) + \lambda \mathcal{R}(f),$$

$\mathcal{L}(f) = \frac{1}{2} \|Af - b\|_2^2$ mesure la **fidélité aux données**, $\mathcal{R}(f)$ modélise un **a priori** sur l'objet reconstruit.

Méthode

1. L'objet reconstruit \hat{f} est considéré comme un champ d'atténuation : $\mathbb{R}^3 \rightarrow \mathbb{R}$. On modélise ce champ par un **champ de neurones (neural field)** [2], paramétré par un **perceptron multicouche** $F_\Phi : \mathbb{R}^3 \rightarrow \mathbb{R}$.
2. On régularise l'optimisation du champ de neurones F_Φ en utilisant la méthode **RED** [3] $\rightarrow H(f) = (f - D_\theta(f))$, avec D_θ un **engin de post-traitement** paramétré par θ .

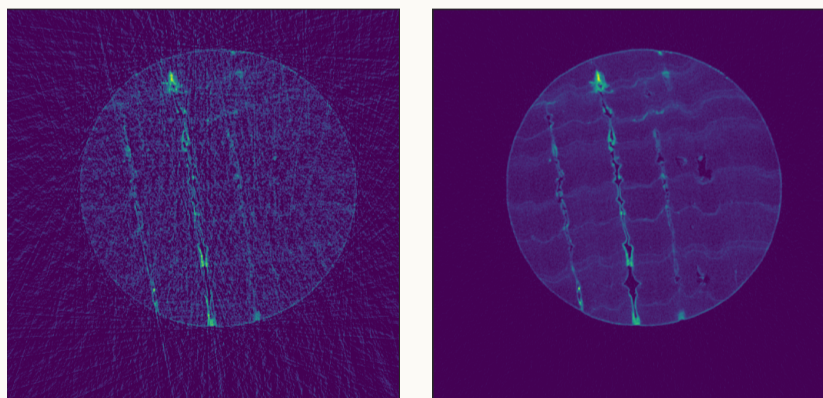
D_θ est un UNet [4], **pré-entraîné pour la suppression d'artefacts** de reconstruction en vues éparses :

$$\hat{\theta} = \arg \min_{\theta} \frac{1}{K} \sum_{i=1}^K \frac{1}{n} \|D_\theta(\tilde{f}_i) - f_i^\dagger\|_2^2$$

Steepest descent RED :


$$\Phi^{(k+1)} = \Phi^{(k)} - \mu \frac{\partial \mathcal{L}}{\partial f} \frac{\partial F_\Phi}{\partial \Phi} - \lambda H(F_{\Phi^{(k)}}) \frac{\partial F_\Phi}{\partial \Phi}$$

Résultats qualitatifs



(a) [50/720] FDK

(b) [720/720] FDK



(c) [50/720]

Post-traitement (D_θ)

(d) [50/720] Champ de neurones régularisé

Figure: Illustrations des résultats sur notre base de données de bouchons en liège naturel. Visualisation d'une coupe transverse reconstruite avec différentes méthodes pour des acquisitions éparses [50/720] ou denses [720/720].

Avantages

1. **Champ de neurones** - représentation **plus légère** qu'une grille dense régulière, **complexité mémoire divisée par 4** en utilisant instant-ngp [2].
2. **RED** combiné avec un **post-traitement appris** - évaluation simple et rapide de l'étape de régularisation

Performances

Cork-CBCT - 3D	pixel	neural	PSNR ↑	SSIM ↑
FDK	✓	-	38.94	0.500
SGD	✓	-	47.16	0.854
Post-traitement (UNet)	✓	-	49.77	0.935
instant-ngp	-	✓	47.28	0.815
RED (UNet)	✓	-	48.85	0.897
Ours: NeF-RED (UNet)	-	✓	48.91	0.895

Table: Comparaison des performances de l'état de l'art sur notre dataset de bouchons en liège naturel.

- [1] Leuschner et al. Quantitative Comparison of Deep Learning-Based Image Reconstruction Methods for Low-Dose and Sparse-Angle CT Applications. *Journal of Imaging*, 7(3):44, March 2021.
- [2] Müller et al. Instant neural graphics primitives with a multiresolution hash encoding. *ACM Transactions on Graphics*, 41(4):1-15, July 2022.
- [3] Romano et al. The Little Engine That Could: Regularization by Denoising (RED). *SIAM Journal on Imaging Sciences*, 10(4):1804-1844, January 2017.
- [4] Ronneberger et al. U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*, Lecture Notes in Computer Science, pages 234-241, Cham, 2015. Springer International Publishing.