

Régularisation par apprentissage profond pour la restauration d'images satellites

Maud Biquard ^{1,3} Marie Chabert ² Florence Genin ³ Christophe Latry ³ Thomas Oberlin ¹

¹ISAE-Supaero ²IRIT/INP-ENSEEIH ³CNES

Résumé

On s'intéresse à la restauration d'images satellites (débruitage et défloutage, avec et sans super-résolution). Les méthodes de régularisation basées sur un réseau de neurones génératif offrent un cadre intéressant mais s'avèrent fortement dépendantes de la qualité du réseau utilisé. On propose ici d'utiliser un auto-encodeur variationnel moins contraint, utilisé originellement pour la compression. De plus, on introduit un cadre bayésien favorable pour échantillonner la distribution a posteriori du problème, permettant la génération de plusieurs images solutions ainsi que d'estimer des incertitudes. Les simulations, sur des images naturelles ainsi que des images satellites, permettent de conclure à des performances similaires à l'état de l'art, et démontrent le potentiel de cette méthode pour la restauration d'images satellites.

Introduction

On considère le problème inverse suivant :

$$y = Ax + n \quad (1)$$

avec y la mesure, A l'opérateur de dégradation, x l'image d'origine et n le bruit.

→ $A = h*$, $n \sim \mathcal{N}(0, \sigma^2 = a^2 + b(h*x))$ pour le débruitage et défloutage d'images satellites.

Classiquement, on recherche la solution du problème (1) sous la forme:

$$\hat{x} = \arg \min_x \|y - Ax\|^2 + \lambda R(x) \quad (2)$$

où R est la régularisation.

→ Apprendre R à l'aide de réseaux de neurones permet d'améliorer considérablement les performances en restauration d'images.

→ Apprendre uniquement R permet de résoudre plusieurs problèmes inverses avec le même réseau de neurones [3].

• Deux possibilités : implicitement à l'aide de débruiteurs [3], ou explicitement à l'aide de modèles génératifs [1].

Régularisation par réseaux génératifs

1. Apprentissage d'un réseau génératif G sur un dataset d'images idéales x .

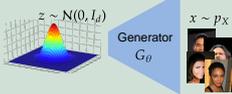


Figure 1. Principe d'un réseau génératif

2. Restauration d'images. On recherche la solution du problème inverse dans l'espace latent de G [2] :

$$\hat{z} = \arg \min_z \|AG(z) - y\|_2^2 + \lambda \|z\|_2^2$$

$$\text{avec } \hat{x} = G(\hat{z}) \quad (3)$$

+ Minimisation d'une fonction de coût explicite

+ Cadre bayésien intéressant : \hat{z} peut être vu comme un estimateur MAP (Maximum A Posteriori)

- La contrainte $x = G(z)$ rend la performance de la méthode très dépendante du modèle génératif utilisé

Utilisation d'une structure d'auto-encodeur compresseur

Auto-encodeur choisi :

- Grand espace latent (= espace encodé).
- Les données sont réparties dans l'espace latent suivant une loi flexible $\mathcal{N}(\mu^z, \sigma^z)$ définie par l'hyperprior.

- Apprentissage de textures et formes.
- Applicable sur des données complexes.

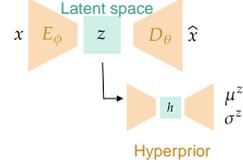


Figure 2. Structure d'auto-encodeur compresseur.

Estimation de la distribution a posteriori du problème

→ Algorithme VBLE [1] : Approximation de distribution a posteriori $p(z|y)$ par un petit volume dans l'espace latent.

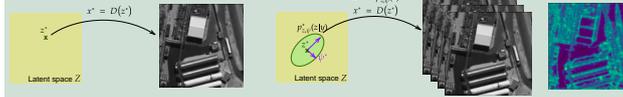


Figure 3. Algorithme déterministe

Figure 4. Notre algorithme (VBLE)

On utilise de l'inférence variationnelle:

→ Définition de la distribution paramétrique

$$E_{z,a} = \left\{ q_{z,a}(z) = \mathcal{U}(z_k; [\bar{z}_k - \frac{a_k}{2}, \bar{z}_k + \frac{a_k}{2}]) \mid \bar{z}, a \in \mathbb{R}^p, a > 0 \right\} \quad (4)$$

→ Minimisation de $KL(q_{z,a}(z) \parallel p_{z|Y}(z|y))$ qui revient à maximiser l'ELBO

$$\arg \max_{z,a} \mathcal{L}_{z,a} = \arg \max_{z,a} \mathbb{E}_{q_{z,a}(z)} [\log p_{Y|Z}(y|z) + \log p_{\theta}(z) - \log q_{z,a}(z)] \quad (5)$$

with $\log q_{z,a}(z) = -\sum_k \log a_k$ and $\log p_{\theta}(z) = R(z)$ the hyperprior.

- Minimisation de (5) par descente de gradient
- Estimateur MMSE: $x_{MMSE-x}^* = \frac{1}{T} \sum_{i=1}^T D_{\theta}(z_i)$ with $z_i \sim q_{z^*,a^*}(z_i)$.

Expérimentations - images naturelles / satellites

- Métriques : PSNR (erreur quadratique en échelle log), SSIM (métrique perceptuelle classique), LPIPS (métrique perceptuelle deep).
- Réseau : Utilisation de réseaux compresseurs préentraînés, finetunés sur les datasets testés.
- Baselines : DPIR/PnP-ADMM (algorithmes Plug&Play avec débruiteur deep), PnP-ULA (algorithme MCMC), DiffPIR (algorithme utilisant des modèles de diffusion)

BSD	Deblur (Gaussian)			SISR x4			SISR x2		
	PSNR ↑	LPIPS ↓	SSIM ↑	PSNR ↑	LPIPS ↓	SSIM ↑	PSNR ↑	LPIPS ↓	SSIM ↑
VBLE wCAE	29.77	<i>0.2002</i>	<i>0.8617</i>	25.47	<i>0.3459</i>	<i>0.6977</i>	29.65	<i>0.1830</i>	<i>0.8749</i>
MAPz wCAE	29.28	0.2215	0.8405	<i>25.38</i>	<i>0.3462</i>	<i>0.6966</i>	29.65	<i>0.1675</i>	<i>0.8757</i>
PnP-ULA	27.71	0.2675	0.7809	24.82	0.3730	0.6894	28.42	<i>0.1659</i>	<i>0.8763</i>
DPIR	<i>29.72</i>	0.2127	0.8623	25.18	0.3652	0.6937	29.55	0.1706	0.8784
PnP-ADMM	28.96	0.2155	0.8456	24.77	0.4227	0.6659	29.31	0.1907	0.8678
DiffPIR	29.26	0.1832	0.8420	25.03	0.3164	0.6771	29.20	0.1645	0.8539

Table 1. BSD results on diverse inverse problems: Gaussian deblurring ($\sigma_{blur} = 1$, $\sigma = 7.65/255$), SISR x4, SISR x2. Methods in *italics* allow for posterior sampling.

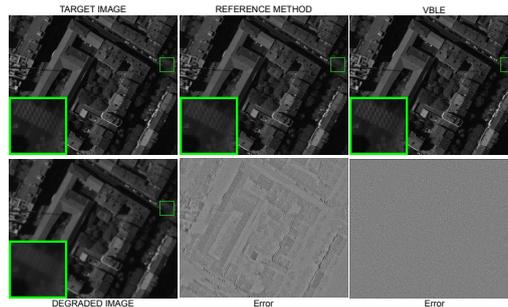


Figure 5. Exemple de restauration au point de fonctionnement Pleiades (50cm). VBLE : notre méthode. Méthode de référence : classiquement utilisée pour restaurer les images satellites (NL-Bayes + déconvolution). Milieu : images restaurées. Bas : Erreur signée $\hat{x} - x$. ©CNES 2024

Expérimentations - Images satellites réelles

- Dataset : Images Pélican (images aéroportées) utilisées pour simuler le point de fonctionnement Pleiades.
- Problèmes considérés : Débruitage + défloutage avec et sans super-résolution.

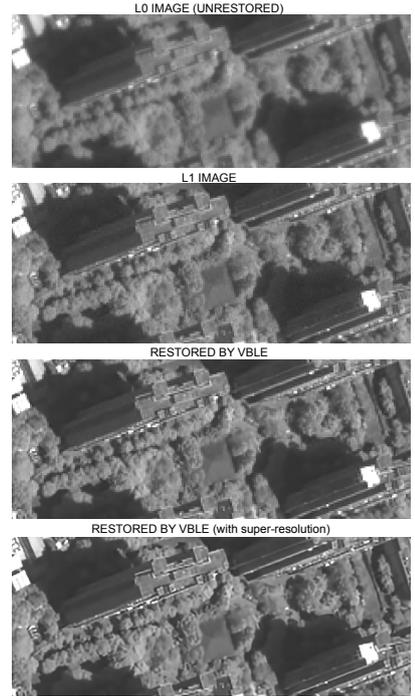


Figure 6. Exemple de restauration d'une image Pleiades réelle. Image L1: restaurée par la méthode de référence. ©CNES 2024

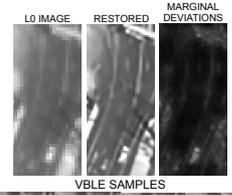


Figure 7. Restauration par VBLE d'une image Pleiades réelle, incertitude et exemple d'échantillons. ©CNES 2024

References

- [1] Maud Biquard, Marie Chabert, Florence Genin, Christophe Latry, and Thomas Oberlin. Variational bayes image restoration with compressive autoencoders. *arXiv preprint arXiv:2311.17744*, 2023.
- [2] Ashish Bora, Ajil Jalal, Eric Price, and Alexandros G. Dimakis. Compressed sensing using generative models. In *International Conference on Machine Learning (ICML)*, 2017.
- [3] Kai Zhang, Yawei Li, Wangmeng Zuo, Lei Zhang, Luc Van Gool, and Radu Timofte. Plug-and-play image restoration with deep denoiser prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(10):6360–6376, 2021.