

## Optimisation convexe en imagerie

|                |                              |
|----------------|------------------------------|
| Encadrant      | Samuel Vaïter                |
| Adresse e-mail | samuel.vaïter@u-bourgogne.fr |

## Contexte

Ce projet concerne la résolution de problèmes inverses linéaires dans le contexte du traitement du signal ou d'image. Un tel problème peut être écrit sous la forme

$$y = \Phi x_0 + w,$$

où  $y \in \mathbb{R}^q$  représente les observations,  $x_0 \in \mathbb{R}^n$  les données inconnues à retrouver,  $\Phi$  un opérateur linéaire de  $\mathbb{R}^n$  dans  $\mathbb{R}^q$  et  $w$  un terme de bruit additif. Ce modèle inclut de nombreux cas typiques en imagerie tels que le débruitage, la déconvolution, l'interpolation, l'échantillonnage compressé ainsi que la tomographie. L'opérateur linéaire  $\Phi$  est généralement mal conditionné et/ou non inversible, ce qui rend *mal posé* le problème de retrouver  $x_0$  à partir de  $y$ . C'est la raison pour laquelle il s'avère nécessaire de mettre en place une stratégie de reconstruction. Un cadre classique est celui des méthodes variationnelles, pouvant s'écrire sous la forme

$$x^* \in \underset{x \in \mathbb{R}^n}{\operatorname{Argmin}} \frac{1}{2} \|y - \Phi x\|_2^2 + \lambda \mathcal{J}(x), \quad (\mathcal{P}_{y,\lambda})$$

où  $\mathcal{J}$  est une fonctionnelle de  $\mathbb{R}^n$  dans  $\mathbb{R}_+$  que l'on considérera convexe mais qui sera typiquement non différentiable. Il s'agit de réaliser un compromis entre fidélité aux données (terme quadratique ici) et régularisation, représentée ici par  $\mathcal{J}$ . Ce compromis est dicté par le choix du paramètre  $\lambda$ . Le choix de  $\mathcal{J}$  est un sujet de recherche en soit. Selon le modèle de signal que l'on pose, on utilise par exemple les normes  $\|\cdot\|_1$  [3],  $\|\cdot\|_\infty$  [2] ou encore des semi-normes comme la variation totale  $\|\nabla \cdot\|_1$  [5].

## Objectif du projet

L'objectif principal du projet sera d'initier l'étudiant à l'optimisation convexe non-lisse d'un point de vue théorique, algorithmique et applicatif. Le stage commencera par une mise à niveau éventuelle sur les concepts de base de l'analyse convexe [4] tel que la convexité, la notion de sous-différentielle ainsi que la dualité de Fenchel-Rockafellar. Il s'agira ensuite de voir comment ces concepts donnent naissance à des algorithmes [1] permettant la résolution d'un problème tel que  $(\mathcal{P}_{y,\lambda})$ , généralisant ainsi la méthode de descente de gradient classique pour des fonctions différentiables. Enfin, l'accent sera mis sur l'implémentation de ces méthodes sur des problèmes choisis en imagerie, par exemple à travers la réalisation d'une mini bibliothèque de méthodes proximales. Le langage de programmation sera libre, avec une préférence pour Python, Julia ou Matlab.

## Bibliographie

- [1] P. L. Combettes and J.-C. Pesquet. "Proximal splitting methods in signal processing". In: *Fixed-Point Algorithms for Inverse Problems in Science and Engineering*. Ed. by H. H. Bauschke, Burachik R. S., P. L. Combettes, Elser. V., D. R. Luke, and H. Wolkowicz. Springer, 2011, pp. 185–212.
- [2] H. Jégou, T. Furon, and J.-J. Fuchs. "Anti-sparse coding for approximate nearest neighbor search". In: *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on*. IEEE, 2012, pp. 2029–2032.
- [3] S. G. Mallat. *A wavelet tour of signal processing*. Third. Elsevier/Academic Press, Amsterdam, 2009.
- [4] R.T. Rockafellar. *Convex analysis*. Vol. 28. Princeton University Press, 1996.
- [5] L.I. Rudin, S. Osher, and E. Fatemi. "Nonlinear total variation based noise removal algorithms". In: *Physica D: Nonlinear Phenomena* 60.1 (1992), pp. 259–268.