

Bornes non-asymptotiques optimales pour la moyennisation de Ruppert-Polyak

Sébastien Gadat, Toulouse School of Economics

Mots-clés : Optimisation stochastique, moyennisation, inégalité de Kurdyka-Lojasiewicz

Nous considérons l'algorithme de Ruppert-Polyak des algorithmes stochastiques introduits par Robbins et Monro:

$$\theta_{n+1} = \theta_n - \gamma_{n+1} \nabla f(\theta_n) + \gamma_{n+1} \Delta M_{n+1},$$

où $-\nabla f(\theta_n) + \Delta M_{n+1}$ est une évaluation non biaisée du gradient d'une fonction f à minimiser, perturbée par un incrément de martingale.

La moyennisation introduite dans [R88, PJ92] consiste à opérer une moyennisation au sens de Cesaro de l'algorithme initial:

$$\bar{\theta}_n = \frac{1}{n} \sum_{i=1}^n \theta_i$$

Dans notre travail, nous présentons des bornes non-asymptotiques optimales (au sens de Cramer-Rao) dans un cadre très général qui permet de gérer à la fois le cas de l'uniforme forte convexité de [BM11] mais aussi les situations plus générales où f satisfait une condition faible de type Kurdyka-Lojasiewicz (voir [K98, L63]).

En particulier, cela nous permet de considérer les exemples problématiques de type régression logistique séquentielle (voir [B14]) ou estimation récursive du quantile. Nous démontrons qu'un schéma optimal est obtenu pour une suite de pas $(\gamma_n)_{n \geq 1}$ donné par $\gamma_n = \gamma_1 n^{-\beta}$ avec $\beta = 3/4$, obtenant ainsi un terme de second ordre en $O(n^{-5/4})$.

Références

- [B14] F. Bach, Adaptivity of averaged stochastic gradient descent to local strong convexity for logistic regression, *Journal of Machine Learning Research*, vol. 15, 595-627 (2014).
- [BM11] F. Bach and E. Moulines, Non-Asymptotic Analysis of Stochastic Approximation Algorithms for Machine Learning, *Neural Information Processing Systems (NIPS)* (2011).
- [K98] K. Kurdyka, On gradients of functions definable in o-minimal structures, *Ann. Inst. Fourier, Université de Grenoble. Annales de l'Institut Fourier*, vol. 48 (3), 769-783 (1998).
- [L63] S. Lojasiewicz, Une propriété topologique des sous-ensembles analytiques réels, *Editions du CNRS, Paris, Les Équations aux Dérivées Partielles*, 87-89 (1963).
- [R88] D. Ruppert, Efficient estimations from a slowly convergent Robbins-Monro process, *Technical Report*, 781, *Cornell University Operations Research and Industrial Engineering*, (1988).
- [PJ92] B. T. Polyak and A. Juditsky, Acceleration of Stochastic Approximation by Averaging, *SIAM Journal on Control and Optimization*, vol. 30 (4), 838-855 (1992).