

Atelier I: Apprentissage/Big Data et Expériences Numériques

L'apprentissage séquentiel comme outil face au big data

Alexandra Carpentier et Clément Chevalier

Exposé introductif

Le phénomène “Big Data” ne se caractérise pas seulement par la massivité des jeux de données, mais aussi par la multiplicité des façons dont ces données peuvent être acquises. De nombreuses applications modernes impliquent une collecte active des données par l'utilisateur - comme par exemple dans le cas des systèmes de recommandation qui n'observent la réaction du client que sur les objets recommandés. Plusieurs problèmes passionnants se posent alors - en particulier, celui de concevoir des techniques optimales de collecte de données. L'importance de ces techniques pour le Big Data est encore soulignée par le fait qu'elles peuvent être (et sont) appliquées pour traiter de façon optimale des bases de données massives, en les utilisant pour effectuer un sous-échantillonnage optimal.

Discussion: Apprentissage séquentiel avec un grand nombre d'options, et/ou en grande dimension

Au cours d'un problème d'apprentissage séquentiel, l'apprenant doit choisir séquentiellement, à horizon n , entre plusieurs (notons K) options. Quand il/elle choisit une option, il/elle reçoit de l'information bruitée sur cette option. La plupart des techniques d'apprentissage séquentiel classique se concentrent sur les cas où l'horizon n est bien plus grand que le nombre d'options K - et ceci implique qu'il est possible à l'apprenant d'essayer chaque option.

Dans le contexte du “Big Data” et de données massives, il n'est pas réaliste de supposer que $K \leq n$. Afin d'utiliser l'apprentissage séquentiel comme outil face au “Big Data”, il est donc important d'avoir des méthodes efficaces aussi dans ce cas là. Nous proposons les deux axes suivants pour orienter la discussion à ce sujet.

1. Un premier axe de discussion concerne les applications modernes de l'apprentissage séquentiel en grande dimension. Cela peut concerner le cas de

données vraiment collectées séquentiellement – par exemple pour les systèmes de recommandation (Li et.al, 2010). Mais il peut également s’agir de données si massives qu’il faut sous-échantillonner les individus ou les options – comme par exemple pour la sélection adaptative de “features” (Gaudel and Sebag , 2010) et la classification active de données massives, c’est à dire en grande dimension (Dubout and Fleuret , 2014). Nous proposons de discuter de quelques unes de ces applications, afin de voir quelles en sont les difficultés et quelles hypothèses sont raisonnables.

2. Un second axe de discussion concerne les méthodes existantes pour l’apprentissage actif quand $K \gg n$. De nombreux exemples de ce problème ont été étudiés récemment, sous des hypothèses variées. On peut distinguer par exemple trois cas intéressants :
 - (a) Le cas où les options sont organisées suivant une certaine “topologie”, en d’autres termes le cas où les options donnent de l’information les unes sur les autres. C’est par exemple le cas de la modélisation par processus Gaussiens (Jones et.al, 1998; Srinivas et.al, 2009; Picheny et.al, 2014; Grünewälder et.al, 2011), ou encore le “Monte-carlo tree search” (Munos, 2014), ou l’active learning (Hanneke , 2009), etc. Dans ce cas, la topologie sur les options est ce qui va permettre de sous-échantillonner, c’est à dire choisir parmi les nombreuses options, de manière efficace.
 - (b) Le cas où l’on ne souhaite pas faire d’hypothèses “topologiques” sur les options, auquel cas il faut quantifier la qualité d’un sous-échantillonnage aléatoire “dans le pire des cas” (Wang et.al, 2008).
 - (c) Le cas de l’apprentissage séquentiel avec information contextuelles : le contexte va encore augmenter la dimension et de nombreux challenges modernes se posent dans ce contexte (Li et.al, 2010; Krause and Ong , 2011).

References

- Dubout, C., and Fleuret, F. Adaptive sampling for large scale boosting. *The Journal of Machine Learning Research*, 15(1), 1431-1453, 2014.
- Hanneke, S. Theoretical foundations of active learning. *ProQuest*, 2009.
- Gaudel, R., and Sebag, M. Feature selection as a one-player game. *In International Conference on Machine Learning*, pp. 359-366, 2010.
- Krause, A., and Ong, C. S. Contextual gaussian process bandit optimization. *In Advances in Neural Information Processing Systems*, pp. 2447-2455, 2011.
- Grünewälder, S., Audibert, J. Y., Opper, M., and Shawe-Taylor, J. Regret bounds for gaussian process bandit problems. *In International Conference on Artificial Intelligence and Statistics.*, pp. 273-280, 2010.

- Jones, Donald R and Schonlau, Matthias and Welch, William J. Efficient global optimization of expensive black-box functions. *Journal of Global optimization*, 13(4):455–492, 1998.
- Li, L., Chu, W., Langford, J., and Schapire, R. E. A contextual-bandit approach to personalized news article recommendation. *In Proceedings of the 19th international conference on World wide web*, (pp. 661-670), 2010.
- Munos, Remi. From bandits to Monte-Carlo Tree Search: The optimistic principle applied to optimization and planning. *Foundations and Trends in Machine Learning*, 7(1):1-130, 2014.
- Victor Picheny and David Ginsbourger and Yann Richet and Gregory Caplin. Quantile-Based Optimization of Noisy Computer Experiments With Tunable Precision. *Technometrics*, 55(1):2–13, 2013.
- Srinivas, N., Krause, A., Kakade, S. M., and Seeger, M. Gaussian process optimization in the bandit setting: No regret and experimental design. *arXiv preprint arXiv:0912.3995*, 2009.
- Wang, Yizao, Jean-Yves Audibert, and Rémi Munos. Algorithms for infinitely many-armed bandits. *Advances in Neural Information Processing Systems*, 2009.