

Рассматривается метод получения ускоренного рандомизированного покомпонентного метода с помощью каплинга (комбинации) неускоренных прямого градиентного метода (ПГМ) и метода зеркального спуска (МЗС). Будем называть такой метод ACRCO (Accelerated by Coupling Randomized Coordinate Descent)

$$ACRCO(\alpha, \tau; x_0, f(x_0) - f_* \leq d)$$

1.  $x_{k+1} = \tau z_k + (1 - \tau)y_k$
2.  $i_{k+1} \in [1, \dots, n]$
3.  $y_{k+1} = \text{Grad}_{i_{k+1}}(x_{k+1})$
4.  $z_{k+1} = \text{Mirr}_{z_k}(\alpha n \nabla_{i_{k+1}} f(x_{k+1}))$

Где Grad() и Mirr() - стандартные шаги алгоритмов методов градиентного и зеркального спуска. Показано, что метод действительно является ускоренным (в смысле зависимости скорости сходимости от  $\varepsilon$  требуемой точности).

Доказана скорость сходимости метода при значении параметра

$$\alpha n^2 = \frac{1 - \tau}{\tau}$$

в среднем:

$$E[f(\bar{x}_k)] - f_* \leq \frac{2n\sqrt{\Theta d}}{K} \leq \frac{d}{2}$$

И по вероятности,

то есть число шагов, за которое гарантировано можно

достичь точности,  $\varepsilon$  с вероятностью, не меньшей  $1 - \sigma$

$$N = O\left(n \sqrt{\frac{\|x_0 - x_*\|^2}{\varepsilon}} \ln\left(\frac{\ln(d/\varepsilon)}{\sigma}\right)\right)$$

Главное преимущество покомпонентных методов - способность учитывать разреженность задачи, то есть вместо зависимости от размерности  $O(n)$  получать скорость  $O(s)$ , где  $s$  -

среднее число ненулевых элементов в матрице(квадратичной целевой) функции. У метода ACRCO для произвольных функций остается зависимость от размерности пространства как  $O(n)$ . Однако, учет разреженности работает для специального вида функций, таких что  $f(x) = \sum f(x_i)$ , таких, как например

$$f(x) = \|Ax - b\|^2$$

Также, преимущество покомпонентных методов заключается в том, что константа Липшица, появляющаяся в оценке есть максимальная константа по всем координатам(ограничение 1 нормы градиента), что меньше, а в случае с плохой обусловленностью сильно меньше, чем просто константа Липшица (ограничение 2 нормы градиента).

Также показано, в какие ограничения нужно наложить на множество  $Q$ , чтобы покомпонентные методы действительно заканчивали работу в точке минимума, так как это не всегда так.

#### Литература

1. *Bubeck S. [at al.] Regret analysis of stochastic and nonstochastic multi-armed bandit problems. // Foundations and Trends in Machine learning. - 2012. - V. 5. № 1. P. 1-122*
2. *Nesterov Y. [at al.] Efficiency of coordinate descent methods on large scale optimization problem. // SIAM Journal on Optimization. 2012. V. 22. No 2. P. 341–362.*
3. *Allen-Zhu Z., Orecchia L. [at al.] Linear coupling: An ultimate unification of gradient and mirror descent // e-print, 2015.*