

Bandit Convex Optimization e o algoritmo FKM

André Mazal Krauss - INF2982 Algoritmos e Incerteza

December 2, 2020

Outline

Bandit Convex Optimization

Resolução do Problema

Tentativas

Flaxman, Kalai, McMahan

OCO via Gradient Descent

Obtenção do Gradiente via One Point Estimation

Bandit Convex Optimization

Definição do Problema

BCO: Deseja-se escolher/jogar, para $t = 1..T$ rodadas, um ponto $x_t \in K$, $K \subset \mathbb{R}^d$, de maneira que minimize o regret dado por:

$$\text{Regret}_T = \sum_{t=1}^T f_t(x_t) - \min_{x \in K} \sum_{t=1}^T f_t(x)$$

Para escolher x_t na rodada t , temos acesso a:

- ▶ x_1, x_2, \dots, x_{t-1}
- ▶ $f_1(x_1), f_2(x_2), \dots, f_{t-1}(x_{t-1})$

Bandit Convex Optimization

Definição do Problema

Online Convex Optimization?

BCO difere do OCO visto em sala em que temos acesso somente a $f_t(x_t)$, e não a outros pontos da função f_t

Bandit Experts?

BCO pode ser entendido como uma extensão do Bandit Experts em que consideramos um espaço $K \subset \mathbb{R}^d$ em vez de um conjunto finito de escolhas.

Bandit Convex Optimization

Tentativa de Resolução

FTRL?

Algorithm 1: Follow the Regularized Leader

x_1 é escolhido;

$R(x)$ é α - fortemente convexo;

for $t = 1..T$ **do**

 Jogue x_t , tome perda $f_t(x_t)$

$x_{t+1} = \operatorname{argmin}_{x \in K} \sum_{k=1}^t f_k(x) + \frac{1}{\eta} R(x)$

end

Bandit Convex Optimization

Tentativa de Resolução

BCO via Experts?

No trabalho 2, construímos um algoritmo para resolução de OCO usando uma 'grid' de experts. Seria possível resolver BCO combinando essa ideia com o algoritmo UCB usado no Bandit Experts?

Algoritmo FKM

OCO via Gradient Descent

Zinkevich - 2003

Algorithm 2: OCO via Gradient Descent

Seja P_K um 'oráculo projetivo', ie:

$$P_K(x) = \operatorname{argmin}_{z \in K} \|x - z\|$$

Seja η uma taxa de aprendizado

x_1 é escolhido

for $t = 1..T$ **do**

 | Jogue x_t , tome perda $f_t(x_t)$
 | $x_{t+1} = P_K(x_t - \eta \nabla f_t(x_t))$

end

Garantias

$$\operatorname{regret} \leq DG\sqrt{T}$$

Algoritmo FKM

One point gradient estimator

2D

Seja:

$$\tilde{f}'(x) = \begin{cases} +\frac{1}{\delta}f(x + \delta) & \text{com prob. } \frac{1}{2} \\ -\frac{1}{\delta}f(x - \delta) & \text{com prob. } \frac{1}{2} \end{cases}$$

Temos portanto:

$$\lim_{\delta \rightarrow 0} \mathbb{E}[\tilde{f}'(x)] = \lim_{\delta \rightarrow 0} \frac{f(x + \delta) - f(x - \delta)}{2\delta} = f'(x)$$

Algoritmo FKM

One point gradient estimator

D-dimensional

$$\tilde{\nabla} f(x) \approx \mathbb{E}[(f(x + \delta u) - f(x))u] \frac{d}{\delta} = \mathbb{E}[f(x + \delta u)u] \frac{d}{\delta}$$

onde u é um vetor unitário aleatório, amostrado uniformemente

Algoritmo FKM

Gradient Descent via Gradient Estimator

Algorithm 3: Bandit Gradient Descent(FKM)

Seja $K_\alpha \subset K$ com α pequeno

Seja P_{K_α} um 'oráculo projetivo', ie:

$$P_{K_\alpha}(x) = \operatorname{argmin}_{z \in K_\alpha} \|x - z\|$$

Seja η uma taxa de aprendizado

$$x_1 = 0$$

for $t = 1..T$ **do**

 amostre um vetor unitário aleatório u

$$y_t = x_t + \delta u$$

 Jogue y_t , tome perda $f_t(y_t)$

$$x_{t+1} = P_{K_\alpha}(x_t - \eta f_t(y_t)u)$$

end

Algoritmo FKM

Garantias

Garantia FKM

Supondo alguns valores para T , δ , η e α , podemos obter:

$$\mathbb{E}\left[\sum_{t=1}^T f_t(x_t)\right] - \min_{x \in K} \sum_{t=1}^T f_t(x) \leq 3CT^{\frac{5}{6}} \sqrt[3]{d \frac{R}{r}}$$

Se adicionalmente considerarmos que cada f_t é L-Lipschitz:

$$\mathbb{E}\left[\sum_{t=1}^T f_t(x_t)\right] - \min_{x \in K} \sum_{t=1}^T f_t(x) \leq 2T^{\frac{3}{4}} \sqrt{3RdC(L + \frac{C}{r})}$$

Referências I



Abraham D. Flaxman, Adam Tauman Kalai, H. Brendan McMahan

Online convex optimization in the bandit setting: gradient descent without a gradient.

2008.



Roi Livni

COS-511 at Princeton - Lecture 23: Bandit Convex Optimization.

2017.



Martin Zinkevich

Online Convex Programming and Generalized Infinitesimal Gradient Ascent

2003.