

## Lecture 7: Online Convex Optimization

25/09/2018

Lecturer: Marco Molinaro

Scribe: Alessandro Soares

## 1 Introdução

Um algoritmo (ou jogo) de Online Convex Optimization (OCO) pode ser descrito da seguinte maneira:

---

### Algorithm 1 Online Convex Optimization

---

```

1:  $P \subseteq \mathbb{R}^n$ 
2: for  $t = 1, \dots, T$  do
3:   Algoritmo escolhe um ponto no playing set ( $x_t \in P$ )
4:   Adversário escolhe função de perda  $f_t$ 
5:   Algoritmo observa função de perda  $f_t$ 
6: end for

```

---

Objetivo do algoritmo:  $\min \sum_{t=1}^T f_t(x_t)$ . Vamos comparar nossa função objetivo com o ótimo que escolhe apenas um  $x$ , isto é:

$$\min \sum_{t=1}^T f_t(x_t) \leq \min_{x \in P} \sum_{t=1}^T f_t(x) + \text{Regret} \quad (1)$$

Note que o OCO nada mais é do que uma generalização do jogo dos experts. Por exemplo, basta fazer:

$$P = \Delta^n$$

$$f_t(x) = \langle l^t, x \rangle$$

E obtemos o problema dos experts.

Nesta aula vamos analisar algoritmos para a resolução de problema desta classe (OCO), que generalizam os problemas vistos até então no curso.

Primeiramente vamos falar do algoritmo "Follow the Leader"(FTL) e vamos analisar o seu REGRET. Uma boa referencia do FTL, para mais detalhes ou coisas especificas, pode ser visto em [3].

Vamos ver que o FTL não é, em algum sentido, estável, e isso faz com que o mesmo tenha alguns resultados relativamente longe do ótimo. Com isso, o algoritmo Follow the Regularized Leader (FTRL) é introduzido, de forma a melhorar a estabilidade do FTL, e obter melhores resultados de Regret. [3] também é uma boa referência para o FTRL.

## 2 Follow the Leader

O FTL é a primeira ideia trivial que temos ao pensar num algoritmo para resolver o OCO. Pois ao avaliar a função de perda  $f_1, \dots, f_{t-1}$ , o algoritmo pode, de forma gulosa, escolher o  $x$  que minimiza a perda considerando todas as funções de perda vistas até então. Em outras palavras:

---

**Algorithm 2** Follow the Leader

---

```
1:  $x_1$  é arbitrário em  $P$ 
2: for  $t = 2, \dots, T$  do
3:    $x_t \in \arg \min_{x_t \in P} \sum_{k=1}^{t-1} f_k(x_t)$ 
4: end for
```

---

Para exemplificar o comportamento do algoritmo num caso concreto, suponha que:

$$P = \Delta^2 \tag{2}$$

$$f_1(x) = \langle (0.1, 0), x \rangle \tag{3}$$

$$f_2(x) = \langle (0, 1), x \rangle \tag{4}$$

$$f_3(x) = \langle (1, 0), x \rangle \tag{5}$$

$$f_4(x) = \langle (0, 1), x \rangle \tag{6}$$

Soluções do FTL:

- $x_1$  é qualquer coisa
- Perda vista até  $T - 1$ :  $0.1x_1 + 0x_2$ . Solução:  $x_2 = (0, 1)$
- Perda vista até  $T - 1$ :  $0.1x_1 + 1x_2$ . Solução:  $x_3 = (1, 0)$
- Perda vista até  $T - 1$ :  $1.1x_1 + 1x_2$ . Solução  $x_4 = (0, 1)$
- ...

Note que o que acontece é que o FTL vai trocando bruscamente de solução a cada iteração, pois a cada uma delas a função de perda faz com que a solução de mínimo mude entre os experts, pois eles vão trocando de quem é melhor e pior.

Agora vamos avaliar quanto custa o algoritmo com as funções de perda reais.

- $t = 1$  qualquer perda
- $t = 2$ :  $x_1 = 0, x_2 = 1$ , Perda =  $0x_1 + 1x_2 = 1$
- $t = 3$ :  $x_1 = 1, x_2 = 0$ , Perda =  $1x_1 + 0x_2 = 1$
- $t = 4$ :  $x_1 = 0, x_2 = 1$ , Perda =  $0x_1 + 1x_2 = 1$

- ...

Desta forma, o algoritmo teve o pior desempenho possível, com custo total  $\simeq T$ .

Para compararmos a performance do algoritmo, vamos considerar o "Ótimo fixo", isto é, o algoritmo offline ótimo que só pode tomar uma única decisão, neste caso a perda do mesmo seria:  $OPT \simeq \frac{T}{2}$ , pois escolheria um dos  $x$  e teria perda = 0 metade do tempo e perda = 1 na outra metade. Assim podemos ver que o REGRET do FTL, neste caso, é:

$$Regret_{FTL} = PERDA - OPT = T - \frac{T}{2}$$

$$Regret_{FTL} = \frac{T}{2} \tag{7}$$

Sendo assim, lembrando que trata-se de um problema genérico do jogo dos experts, a fim de comparação, o regret do MWU em função do T era na ordem de  $\sqrt{T}$  (para mais detalhes, verificar em [1]), o que nos dava o resultado interessante de que na média, nosso regret em relação ao OPT era perto de 0.

Sendo assim, concluímos que o FTL na verdade tem uma performance muito baixa comparado com outros tipos de algoritmos para resolver problemas similares, sendo assim é necessário alguma outra solução melhor.

Podemos verificar que o problema do FTL é que o mesmo fica trocando muito abruptamente de solução, o que o deixa muito exposto à avaliação das funções de perda sem se preocupar com as decisões anteriores em algum sentido. Com isso em mente, vamos ver o Lemma 2.1 que mostra um bound para o Regret do FTL, com considerações sobre sua estabilidade:

**Lemma 2.1.** (BTL-FTL)  $Regret\ do\ FTL \leq \sum_{t=1}^T (f_t(x_t) - f_t(x_{t+1}))$

Considerando o Lema, se a solução do algoritmo na instância é estável, isto é  $x_{t+1} \simeq x_t \Rightarrow REGRET \cong 0$ .

Claro que o Lema só vale para o algoritmo FTL, qualquer outro algoritmo que, de alguma forma, fixe a solução, o Lema não necessariamente valeria mais.

Por exemplo, vamos utilizar o Lemma num jogo onde as funções de perda são sempre iguais, i.e.,  $f_1 = f_2 = \dots = f_T = f$ . Neste caso, vamos ver como o FTL toma as decisões:

- $x_1$  é qualquer coisa
- $x_2 \in \arg \min_x f(x)$
- $x_3 \in \arg \min_x 2f(x)$
- De forma geral:  $x_t \in \arg \min_x (t-1)f(x)$

Note que, como as funções se repetem, e as funções de perda só se diferem por uma constante multiplicativa, a solução de mínimo é sempre igual, i.e:

$$\arg \min k f(x) = \arg \min f(x) \quad \forall k \in R^+ \tag{8}$$

Sendo assim todas as decisões  $x_1 = x_2 = \dots = x_T$  serão iguais. E pelo Lema 2.1, o Regret é igual a zero neste caso. Esse resultado é fácil de interpretar, pois como todas as funções são iguais, por definição, estamos no tempo  $t$  minimizando as perdas até o tempo  $t - 1$  mas que é igual às perdas até o tempo  $t$  fora uma constante.

*Demonstração do lema.* Por definição do FTL que  $x_{t+1}$  seja a melhor solução para as perdas até tempo  $t$ .

Sendo assim:  $OPT = x_{T+1}$ .

O Regret do FTL é então:

$$\sum_{t=1}^T (f_t(x_t) - f_t(OPT)) = \sum_{t=1}^T (f_t(x_t) - f_t(x_{T+1}))$$

Sendo assim, reescrevendo o Lema, queremos provar que:

$$\sum_{t=1}^T (f_t(x_t) - f_t(x_{T+1})) \leq \sum_{t=1}^T (f_t(x_t) - f_t(x_{t+1}))$$

Cortando a primeira parcela ( $\sum_{t=1}^T f_t(x_t)$ ), ficamos com:

$$\sum_{t=1}^T f_t(x_{t+1}) \leq \sum_{t=1}^T f_t(x_{T+1}) \tag{9}$$

Vamos terminar a prova usando indução. Então supondo que vale para  $T - 1$ :

$$\sum_{t=1}^{T-1} f_t(x_{t+1}) \leq \sum_{t=1}^{T-1} f_t(x_T) \leq \sum_{t=1}^{T-1} f_t(x_{T+1}),$$

aonde a ultima desigualdade  $\sum_{t=1}^{T-1} f_t(x_T) \leq \sum_{t=1}^{T-1} f_t(x_{T+1})$ , pois a solução  $x_T$  é a ótima em  $t = T$  e portanto a solução  $x_{T+1}$  é por definição mais cara em  $t = T$ . Agora basta somar  $f_T(x_{T+1})$  em ambos os lados da expressão acima:

$$\sum_{t=1}^{T-1} f_t(x_{t+1}) + f_T(x_{T+1}) \leq \sum_{t=1}^{T-1} f_t(x_{T+1}) + f_T(x_{T+1})$$

Colocando para dentro do somatório para terminar a prova:

$$\sum_{t=1}^T f_t(x_{t+1}) \leq \sum_{t=1}^T f_t(x_{T+1})$$

□

### 3 Follow the Regularized Leader

A principal lição do Lema 2.1 é: Caso o FTL seja estável, ele é necessariamente ótimo! Mas claro que isso nem sempre é verdade. Dito isso, é razoável procurarmos algoritmos parecidos com o FTL, só que buscando, em algum sentido, a estabilidade do mesmo. Algumas idéias são:

- Penalizar o algoritmo por trocas de solução
- Estabilizar as decisões com uma especie de combinação convexa entre o FTL e  $x_{t-1}$
- Regularização para evitar overfitting do passado.

Nesta aula vamos focar nesta ultima idéia de regularização. Mas como regularizar o FTL? Podemos adicionar um termo de regularização na função de minimo das perdas:

$$x_t \in \arg \min_{x \in P} \left\{ \sum_{t=1}^{T-1} f_t(x) + \frac{1}{\eta} \|x\|^2 \right\} \quad (10)$$

A idéia é penalizar soluções muito longe da origem. Porém a regularização pode ser qualquer função  $\alpha$  - fortemente convexa, de acordo com a Definição 1.

$$x_t \in \arg \min_{x \in P} \left\{ \sum_{t=1}^{T-1} f_t(x) + \frac{1}{\eta} R(x) \right\} \quad (11)$$

**Definicao 1.**  $f$  é  $\alpha$  - fortemente convexa se  $\forall x, y$   $f(y) \leq f(x) + \langle \nabla f(x), y - x \rangle + \frac{\alpha}{2} \|y - x\|^2$

Em português,  $f$  é  $\alpha$  - fortemente convexa se a mesma é uma função convexa mais um termo quadrático pequeno. Exemplo:  $\frac{1}{2}x^2$  é 1-fortemente convexa;  $\frac{1}{2}\|x\|_2^2 = \frac{1}{2} \sum_i x_i^2$  é 1-fortemente convexa também.

---

#### Algorithm 3 Follow the Regularized Leader

---

- 1:  $x_1$  é escolhido
  - 2:  $R(x)$  é  $\alpha$  - fortemente convexo
  - 3: **for**  $t = 1, \dots, T$  **do**
  - 4:  $x_t \in \arg \min_{x_t \in P} \left\{ \sum_{k=1}^{T-1} f_k(x_t) + \frac{1}{\eta} R(x) \right\}$
  - 5: **end for**
- 

Vamos usar o FTRL no exemplo onde o FTL tinha ido mal, para ver se a regularização realmente ajuda.

$$P = \Delta^2$$

$$R(x) = \frac{1}{2}(x_1^2 + x_2^2)$$

$$f_1(x) = \langle (0.1, 0), x \rangle$$

$$f_2(x) = \langle (0, 1), x \rangle$$

$$f_3(x) = \langle (1, 0), x \rangle$$

$$f_4(x) = \langle (0, 1), x \rangle$$

Soluções do FTRL, usando que  $x_2 = 1 - x_1$

- $x_{t=1} = (0.5, 0.5)$ , poderia ser qualquer coisa.
- $x_{t=2} = \arg \min_{x_1 \in [0,1]} (0.1x_1 + 2x_1^2 - 2x_1 + 1) = (0.45, 0.55)$
- $x_{t=3} = \arg \min_{x_1 \in [0,1]} (0.1x_1 + 3x_1^2 - 4x_1 + 2.5) = (0.725, 0.275)$

Aqui percebemos que a solução de  $x_3$  ainda muda o expert no qual o algoritmo "prefere", porém a transição é muito mais suave, o que ocorreu por conta da regularização.

Qual seria a sensibilidade (ou "função") do  $\eta$  neste caso?

- Se  $\eta \rightarrow \infty \rightarrow \text{FTRL} = \text{FTL}$  (Não estável)
- Se  $\eta \rightarrow 0 \rightarrow \text{FTRL}$  esquece a história e minimiza a regularização (não aprende)

**Lemma 3.1.** *Regret FTRL é  $\leq 2G\sqrt{T\frac{\Theta}{\alpha}}$ , onde:*

- Onde  $G$  é o Upper-Bound para o gradiente das funções de perda:  $\|\nabla f_t(x)\| \leq G$  (Mede o quão rapidamente as funções de perda crescem).
- $\Theta$  é o tamanho da regularização:  $\Theta \geq R(x) - R(y) \forall x, y$ . Logo:

$$\Theta \geq \max_{x \in P} R(x) - \min_{x \in P} R(x)$$

- $\alpha$  é o nível de fortemente convexo das funções de regularização, que devem ser  $\alpha$ -fortemente convexas.

Este bound é, em algum sentido, o que estávamos procurando, pois tem a  $\sqrt{T}$  aparecendo, ao invés de um  $T$ .

Analizando a sensibilidade do bound, se por exemplo a gente colocasse  $\alpha$  muito grande, o  $\Theta$  iria compensá-lo de alguma forma (pois as funções de perda teriam picos muito grandes), não fazendo muito sentido escolher, por exemplo,  $\alpha$  muito grande, o que poderia parecer uma boa idéia olhando para o Regret.

*Demonstração do Lema 3.1.* Para provar o Lema 3.1, vamos considerar os seguintes lemas abaixo:

**Lemma 3.2.** *Regret FTRL  $\leq \sum_{t=1}^T [f_t(x_t) - f_t(x_{t+1})] + \frac{1}{\eta}\Theta$*

Note que a primeira parcela do REGRET é relativo à estabilidade e a segunda parcela ao tamanho da função de regularização.

*Demonstração do Lema 3.2.* Usando o Lema 2.1, a ideia da prova é:

- Adicione tempo 0  $f_0(x) = \frac{1}{\eta}R(x)$
- FTRL = BTL-FTL no jogo extendendo com o tempo 0
- Aplica Lema 2.1 e desconta o  $f_0$  pois não faz parte do jogo real.

Aplicando o Lema 2.1 ao jogo extendido:

$$\begin{aligned}
 REGRET &\leq \sum_{t=0}^T (f_t(x_t) - f_t(x_{t+1})) \\
 REGRET &\leq \sum_{t=1}^T (f_t(x_t) - f_t(x_{t+1})) + \frac{1}{\eta}R(x_0) - \frac{1}{\eta}R(x_1) \\
 REGRET &\leq \sum_{t=1}^T (f_t(x_t) - f_t(x_{t+1})) + \max_{x \in P} \frac{1}{\eta}R(x) - \min_{x \in P} \frac{1}{\eta}R(x) \\
 REGRET &\leq \sum_{t=1}^T (f_t(x_t) - f_t(x_{t+1})) + \frac{1}{\eta}\Theta
 \end{aligned}$$

□

**Lemma 3.3.** *Se  $R$  é  $\alpha$ -fortemente convexa, então:*

$$f_t(x_t) - f_t(x_{t+1}) \leq \frac{\eta}{\alpha}G^2$$

*Demonstração.* A demonstração completa do Lema 3.3 pode ser vista em [2]. Aqui vamos mostrar para o caso especial:

$$\begin{aligned}
 P &= \Re^n \\
 R &= \frac{1}{2}\|x\|_2^2 \quad (\alpha = 1) \\
 f_t(x) &= \langle l^t, x \rangle
 \end{aligned}$$

Note que  $\frac{\partial f_i}{\partial x_i} = l_i^t$ , e portanto pela hipotese  $\|l^t\| \leq G$ :

$$\begin{aligned}
 f_t(x_t) - f_t(x_{t+1}) &= \langle l^t, x_t \rangle - \langle l^t, x_{t+1} \rangle \\
 f_t(x_t) - f_t(x_{t+1}) &= \langle l^t, x_t - x_{t+1} \rangle \\
 f_t(x_t) - f_t(x_{t+1}) &= \|l^t\| \|x_t - x_{t+1}\| \cos(\theta) \\
 f_t(x_t) - f_t(x_{t+1}) &\leq \|l^t\| \|x_t - x_{t+1}\| \\
 f_t(x_t) - f_t(x_{t+1}) &\leq G \|x_t - x_{t+1}\|
 \end{aligned} \tag{12}$$

Agora vamos utilizar o algoritmo FTRL e calcular  $x_t$  explicitamente:

$$\min \underbrace{\langle l^1, x \rangle + \dots + \langle l^{t-1}, x \rangle + \frac{1}{2\eta} \|x\|_2^2}_{=F}$$

Derivando e igualando a zero:

$$\begin{aligned} \nabla F(x) &= 0 \\ \frac{\partial F}{\partial x_i}(x) &= (l_i^1 + \dots + l_i^{t-1}) + \frac{1}{\eta} x_i = 0 \end{aligned}$$

$$x_i = -\eta \sum_{j=1}^{t-1} l_i^j$$

Escrevendo  $x$  na forma vetorial:

$$x^t = -\eta \left( \sum_{j=1}^{t-1} l^j \right)$$

$$x^{t+1} = -\eta \left( \sum_{j=1}^t l^j \right)$$

$$x^t - x^{t+1} = \eta \left( \sum_{j=1}^t l^j \right) - \eta \left( \sum_{j=1}^{t-1} l^j \right) = \eta \left( \sum_{j=1}^{t-1} l^j \right) - \eta \left( \sum_{j=1}^{t-1} l^j \right) - \eta l^t$$

$$x^t - x^{t+1} = -\eta l^t$$

$$\|x^t - x^{t+1}\| = \eta \|l^t\|$$

$$\|x^t - x^{t+1}\| \leq \eta G$$

(13)

Substituindo a Equação (13) na Equação (12):

$$f_t(x_t) - f_t(x_{t+1}) \leq \frac{\eta G^2}{1} \quad (14)$$

Terminando assim a prova do Lema 3.3, para o caso especial descrito, onde  $\alpha = 1$  □

Voltando à prova do Lema 3.1:

$$\text{Regret}_{FTRL} \leq \frac{1}{\alpha} T \eta G^2 + \frac{1}{\eta} \Theta$$

Agora temos que escolher  $\eta$  de forma a minimizar o  $\text{Regret}_{FTRL}$ . Para isto, basta fazer:

$$\frac{\partial}{\partial \eta} \left( \frac{1}{\alpha} T \eta G^2 + \frac{1}{\eta} \Theta \right) = 0$$



$$\frac{1}{\alpha}TG^2 - \frac{\Theta}{\eta^2} = 0$$

$$\eta = \frac{1}{G}\sqrt{\frac{\alpha\Theta}{T}}$$

$$\text{Regret}_{\text{FTRL}} \leq \frac{TG}{\alpha} \sqrt{\frac{\alpha\Theta}{T}} + \frac{G\Theta}{\sqrt{\frac{\alpha\Theta}{T}}}$$

$$\text{Regret}_{\text{FTRL}} \leq \frac{TG}{\alpha} \sqrt{\frac{\alpha\Theta}{T}} + \frac{GT}{\alpha} \sqrt{\frac{\alpha\Theta}{T}}$$

$$\text{Regret}_{\text{FTRL}} \leq 2\frac{TG}{\alpha} \sqrt{\frac{\alpha\Theta}{T}}$$

$$\text{Regret}_{\text{FTRL}} \leq 2TG\sqrt{\frac{\Theta}{\alpha T}}$$

$$\text{Regret}_{\text{FTRL}} \leq 2G\sqrt{\frac{T\Theta}{\alpha}}$$

Terminando assim, a prova do Lema 3.1. □

Agora vamos aplicar a garantia do FTRL ao problema dos experts abstrato. Para isso vamos analisar cada uma das parcelas que compõe o jogo, tais como o *playing set*, as funções de perdas e a função de regularização, e aplicar suas características no Regret do FTRL para o OCO:

- Espaço do *playing set*:  $P = \Delta^m$
- Funções de perdas:  $f_t(x) = \langle l^t, x \rangle$
- Função de regularização:  $R(x) = \frac{1}{2}\|x\|_2^2$  Implica num  $\alpha$ -FC de  $\alpha = 1$
- Analizando o maior gradiente das funções de perdas:  $G = \nabla f_t = l^t = \|l^t\| \leq \|(1, 1, 1, 1, \dots, 1)\|$
- $G \leq \sqrt{\sum_{i=1}^m 1} \leq \sqrt{m}$
- $\Theta$  é definido como  $\max R(x) - \min R(x)$
- $\Theta : \min R(x) = 0$
- $\Theta : \max R(x) = \max_{x \in \Delta^m} \frac{1}{2}\|x\|_2^2 = \frac{1}{2}$
- $\Theta : \frac{1}{2} - 0 = \frac{1}{2}$

$$FTRL \leq 2G\sqrt{\frac{T\Theta}{\alpha}}$$

$$FTRL \leq 2\sqrt{\frac{Tm}{2}}$$

Para esse problema dos experts, a melhor garantia com MWU é  $2\sqrt{\frac{T\log(m)}{2}}$ .

A diferença entre o FTRL e o MWU nesse caso é um  $\sqrt{m}$  contra um  $\sqrt{\log(m)}$ . Apesar do MWU ser marginalmente melhor, esta tudo bem, pois conseguimos um algoritmo muito mais customizável e genérico que o MWU, com uma garantia quase que tão boa quanto.

Outra observação interessante é que o MWU pode ser derivado do FTRL, com a seguinte regularização:

$$R(x) = \sum_i x_i \log(x_i) \quad (15)$$

Esse fato mostrado na Equação (15) levanta outras questões como: Como escolher a regularização ótima? Essas questões dependem de, por exemplo, a geometria do playing set  $P$ .

## Referências

- [1] E. Hazan, A. Agarwal, and S. Kale. Logarithmic regret algorithms for online convex optimization. *Machine Learning*, 69(2-3):169–192, 2007.
- [2] B. McMahan. Follow-the-regularized-leader and mirror descent: Equivalence theorems and  $\ell_1$  regularization. In *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, pages 525–533, 2011.
- [3] S. Shalev-Shwartz et al. Online learning and online convex optimization. *Foundations and Trends® in Machine Learning*, 4(2):107–194, 2012.