

# Bandidos Multibrazos

Alvaro J. Riascos Villegas  
Universidad de los Andes y Quantil

Agosto de 2024

# Contenido

- 1 Bandidos Multibrazos
  - Ejemplos: Bernoulli y distancia más corta
  - Algoritmos: Explorar primero,  $\epsilon$  - greedy y UCB1
  - Bandidos con Mochilas
  - Algoritmos
  
- 2 Bandidos Multibrazos Combinatorios
  - Algoritmos

## El problema formal

- Sean  $K$  variables aleatoria  $X_{i,t}$  (i.e., armas) con soporte en  $[0, 1]$ .
- $X_{i,t}$  indica el resultado de la  $i$ -ésima arma en el  $t$ -ésimo disparo.
- Asumimos que las variables  $\{X_{i,t} \mid t \geq 1\}$  son i.i.d en  $t$  de acuerdo con una distribución con media desconocida  $\mu_i$ ,  $\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_M)$ .
- Obsérvese que las variables  $X_{i,t}$  pueden estar correlacionadas en  $i$ .
- Cada ronda  $t$  el agente elige una arma  $i$  para disparar y observa la recompensa  $X_{i,t}$ .
- El objetivo el valor acumulado de la recompensas en  $T$  rondas:  $\sum_{t=1}^T X_{i,t} I_{[A_t=i]}$  donde  $A_t$  es la acción (arma) que se elige disparar en  $t$ .

# Ejemplo: Bernoulli

- Supongamos que tres armas  $X_{i,t}$  que se distribuyen Bernoulli,  $Bern(\theta_i)$ .
- Cuando se dispara una arma se recibe una recompensa de 1 de lo contrario cero.

# Ejemplo: Bernoulli

- Supongamos que despues de interactuar con el sistema se tiene el siguiente conocimiento sobre la recompensa promedio de cada acción:




Figura: Densidad de probabilidad sobre recompensas promedio

- En promedio las acción 2 es más alta pero la acción 3 tiene mucha incertidumbre.

# Ejemplo: Bernoulli

- Esta incertidumbre se puede deber a que se ha disparado poco y un algoritmo que no tenga en consideración esto podría no elegir, eventualmente, la mejor acción.
- Un algoritmo  $\epsilon$ -codicioso explora con la misma probabilidad cada una de la acciones. Esto puede ser ineficiente porque la acción 2 parece estar dominada or la acción 1 mientras que la acción 3 es promisoría.
- UCB y Thompson Sampling son formas de atacar ese problema.

## Ejemplo: Caminos más cortos en un grafo

- Una persona desea ir del punto 1 al 12 y los tiempos de desplazamiento  $X_{i,t}$  son inciertos.




Figura: Camino más corto

- Las acciones son caminos en el grafo entre 1 y 12. Un camino  $a_t$  es una sucesión de enlaces  $a_t = (e_1, \dots, e_k)$ .
- El objetivo es minimizar:  $c_t = \sum_{e \in a_t} X_{t,e}$

## Explorar primero

- 1 Fase de exploración: disparar cada arma  $N$ -veces (donde  $N$  es un parámetro del algoritmo).
- 2 Elegir la acción con mayor recompensa.
- 3 Jugar esa acción en todas las rondas que faltan.

- La forma estándar de evaluar un algoritmo es usando el concepto de arrepentimiento (*regret*):

$$R(T) = T \max_a q_t(a) - \sum_{t=1}^T q_t(a) \quad (1)$$

donde en esta notación  $q_t(a) = E[X_{t,a}]$

- Obsérvese que entre mayor el arrepentimiento pero es la estrategia que ha generado el algoritmo.
- Para el algoritmo explorar primero se conoce el siguiente resultado:

$$E[R(T)] \leq T^{\frac{2}{3}} \times O(K \log(T))^{\frac{1}{3}} \quad (2)$$

- La cota superior sobre el arrepentimiento del algoritmo anterior es bastante grande.
- $\epsilon$  - greedy y UCB1 son mejoras sutanciales.

# Bandidos con Mochilas

- Los problemas de bandidos con mochilas (*bandits with knapsacks*) es un modelo general para imponer restricciones al problema de bandidos estudiado hasta este punto.

# Ejemplo: pricing dinámico con oferta limitada

- El problem es:
  - Un vendedor tiene  $B$  productos identicos para vender.
  - Debe intentar hacer en  $T$  rondas de interaccion con los consumidores. Cada interacción es una oferta tomelo o dejelo con un unico consumidor.
  - En cada ronda el vendedor anuncia el precio de venta  $p_t \in [0, 1]$ . El comprador recibe una valoración privada  $v_t$  realización de una distribucion desconocida  $D$ .
  - El comprador compra el producto si  $p_t < v_t$ .
  - El objetivo del vendedor es maximizar las ventas en la  $T$  rondas.
- Si  $B = T$  realmente no hay restricción porque igual el máximo número de items que se pueden vender en  $T$  interacciones es  $T$ .
- Si  $B < T$ , si hay una restricción de oferta limitada en todas las rondas (i.e., global).
- Este es un problema de bandidos con un continuo de armas todas con la misma distribucion de recompensas. Una accion es  $p_t \in [0, 1]$

# Ejemplo: pricing dinámico de varios productos con oferta limitada:

- El problem es:
  - Un vendedor tiene  $n$  productos para vender y un inventario limitado  $B_1, \dots, B_n$  de ada uno.
  - Debe intentar venderlos en  $T$  rondas de interacción con los consumidores. Cada interacción es una oferta tomelo o dejelo con un unico consumidor.
  - En cada ronda el vendedor anuncia el precio de los  $n$  productos  $p_{t,i} \in [0, 1]$ . El comprador recibe una valoración privada  $v_{t,i}$  de cada producto, realización de una distribución desconocida  $D$ .
  - El comprador compra el producto si  $p_{t,i} < v_{t,i}$ .
  - El objetivo del vendedor es maximizar las ventas en la  $T$  rondas.
- Si  $B = T$  realmente no hay restricción porque igual el máximo número de items que se pueden vender en  $T$  interacciones es  $T$ .
- Si  $B < T$ , si hay una restricción de oferta limitada en todas las rondas (i.e., global).

## Bandidos con Mochilas Formalmente

- Supongamos que tenemos  $K$  armas y  $d$  recursos con presupuestos  $B_1, \dots, B_d \in [0, T]$ .
- En cada ronda:
  - 1 Elegir  $a_t \in \{1, \dots, K\}$
  - 2 Se observa  $(r_t; c_{t,1}, \dots, c_{t,d}) \in [0, 1]^{d+1}$  donde  $r_t$  es la recompensa y  $c_{t,i}$  es consumo del recurso  $i$ .
  - 3 El algoritmo para cuando algún recurso consume la totalidad de su presupuesto.

# Aplicaciones

- Pricing dinamico uno o varios productos.
- Pricing dinamico para contratar.
- Pago por click en subastas de avisos publicitarios.
- Subastas repetidas.
- Ofertas dinámicas en una subasta con un presupuesto.

## Aplicaciones: Pricing dinamico

- El problema anterior se puede escribir como un problema con dos recursos, el tiempo  $T$  y el inventario del producto.
- Se observa  $(p, 1, 1)$  si el precio es aceptado y  $(0, 0, 1)$  si no es aceptado.

## Aplicaciones: Pricing dinámico de varios productos

- El problema anterior se puede escribir como un problema con  $K + 1$  recursos, el tiempo  $T$  y el inventario de cada producto.
- Se observa  $(r, 1, 1, \dots, 0, 1, \dots, 1)$  si se vende algún producto, donde  $r$  son los ingresos por las ventas totales.  $(0, 0, \dots, 0, 1)$  si no es aceptado.

# UcbBwK

- El algoritmo que resuelve este problema con una buena garantía de desempeño es una extensión de UCB1.

# Contenido

- 1 Bandidos Multibrazos
  - Ejemplos: Bernoulli y distancia más corta
  - Algoritmos: Explorar primero,  $\epsilon$  - greedy y UCB1
  - Bandidos con Mochilas
  - Algoritmos
  
- 2 Bandidos Multibrazos Combinatorios
  - Algoritmos

## El problema formal

- Sean  $M$  variables aleatoria  $X_{i,t}$  (i.e., armas) con soporte en  $[0, 1]$ .
- $X_{i,t}$  indica el resultado de la  $i$ -ésima arma en el  $t$ -ésimo disparo.
- Asumimos que las variables  $\{X_{i,t} \mid t \geq 1\}$  son i.i.d en  $t$  de acuerdo con una distribución con media desconocida  $\mu_i$ ,  $\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_M)$ .
- Obsérvese que las variables  $X_{i,t}$  pueden estar correlacionadas en  $i$ .
- Cada ronda del juego el agente elige un subconjunto  $S \subset \{1, \dots, M\}$  de armas para disparar. Decimos que  $S$  es una super arma.
- En cada ronda solo se observa el disparo de las armas en la super arma.
- Por simplicidad suponemos que  $|S| = k$  para un  $k$  conocido.

# El problema formal

- Para cada arma  $i \in \{1, \dots, M\}$ , donde  $M$  es el número total de armas, sea  $T_i(t)$  el número de veces la arma  $i$  se ha disparado en  $t$  rondas. Si una arma no se dispara en la ronda  $t$  entonces  $T_{i,t} = T_{i,t-1}$ .
- Sea  $R_t(S)$  las variables aleatorias no negativas que representan la recompensa en  $t$  cuando la super arma  $S$  se juega.
- Suponemos  $R_t(S)$  es de la forma  $R_t(S) = \sum_{i \in S} X_{i,T_{i,t}}$ .
- $R_t(S)$ ,  $E[R_t(S)]$ , es una función de  $S$  y los parámetros  $\mu_i$  de las armas en  $S$ .
- El problema que queremos resolver es encontrar un algoritmo, un método para elegir una super arma en cada ronda  $t$ , tal que maximice el valor esperado de la recompensa en cada ronda  $t$ :  $E[R_t(S)] = \sum_{i \in S} \mu_i$ , para un vector de parámetros  $\mu$  desconocidos.

## CUCB

- 1 For each arm  $i$ , maintain: (1) variable  $T_i$  as the total number of times arm  $i$  is played so far; (2) Variables  $\hat{\mu}_i$ , as the mean of all outcomes  $X_{i,t}$  for  $1 \leq i \leq M$  that have been observed up to round  $t$  (initially 1).
- 2  $t \leftarrow t + 1$ . For each arm  $i$ , set  $\bar{\mu}_i = \min \left\{ \hat{\mu}_i + \sqrt{\frac{3 \ln t}{2T_i}}, 1 \right\}$ .  $S = \text{Oracle}(\bar{\mu}_1, \bar{\mu}_2, \dots, \bar{\mu}_m)$ . Play  $S$ . Observe outcomes of played base arms  $i$ , and update all  $T_i$ 's and  $\hat{\mu}_i$ 's.