

# Algoritmos Aleatorizados

Gabriel Diéguez Franzani

November 29, 2011

- 1 Motivación
- 2 Algoritmos aleatorizados
  - Definición y propiedades
  - Las Vegas y Monte Carlo
  - Complejidad
- 3 Random Treaps
  - Introducción
  - Juegos de Mulmuley
  - Análisis de Treaps

- Existen situaciones en que los algoritmos convencionales presentan problemas
  - Alta complejidad
    - En el sentido “clásico”, no el de Ciencia de la Computación
  - Casos extremadamente malos... como Quicksort con una entrada ordenada
- Parece ser que el determinismo no siempre es nuestro aliado
- **Idea:** usar una componente aleatoria!

## Definición

Un **algoritmo** se dice **aleatorizado** si usa algún grado de aleatoriedad como parte de su lógica.

- Dos grandes ventajas:
  - Simpleza
  - Rapidez
- Pero hay un costo...
  - El tiempo de ejecución del algoritmo, su output o ambos se convierten en **variables aleatorias**.

## Ejemplo: RandQS

- El “mejor” algoritmo de ordenación?
  - Quicksort!
- Su mayor dificultad: elegir el pivote...
- Y si lo elegimos aleatoriamente?
  - Mucho más simple!
  - Tiempo esperado de ejecución:  $O(n \log n)$ , **independiente** del input!

Hablamos del tiempo de ejecución y del output de los algoritmos aleatorizados como variables aleatorias. A partir de esto definimos dos tipos de AAs:

- **Las Vegas:** algoritmos que siempre entregan el resultado correcto, pero cuyo tiempo de ejecución varía (incluso para el mismo input).
  - Un algoritmo Las Vegas se dice **eficiente** si su tiempo esperado de ejecución es polinomial para cualquier entrada.
- **Monte Carlo:** algoritmos que pueden entregar resultados incorrectos con una probabilidad acotada.
  - Podemos disminuir esta probabilidad de error repitiendo el algoritmo... a expensas del tiempo de ejecución.
  - Un algoritmo Monte Carlo se dice **eficiente** si su tiempo de ejecución en el peor caso es polinomial para cualquier entrada.

- El modelo subyacente a los algoritmos aleatorizados es la **Máquina de Turing probabilística**.
- Usa un string de bits aleatorios distribuidos uniformemente como input auxiliar.
- Idea: alcanzar un buen rendimiento en el **caso promedio** sobre todas las posibles elecciones de bits aleatorios.
- Las variables aleatorias que definen el tiempo de ejecución y el output del algoritmo están determinadas por estos bits aleatorios.

## *RP* (Randomized Polynomial time)

Lenguajes que tienen un algoritmo aleatorizado  $A$  tal que:

- Su tiempo de ejecución es polinomial en el peor caso
- Para cualquier entrada  $x$  en  $\Sigma^*$ :
  - $x \in L \Rightarrow Pr[A \text{ acepta } x] \geq \frac{1}{2}$
  - $x \notin L \Rightarrow Pr[A \text{ acepta } x] = 0$

### Observación

Un algoritmo en  $RP$  es un algoritmo *Monte Carlo* que sólo falla cuando  $x \in L$ . Esto se conoce como *one-sided error*.



## *ZPP* (Zero-error Probabilistic Polynomial time)

Lenguajes que tienen un algoritmo aleatorizado  $A$  tal que:

- No fallan en el output
- Su tiempo de ejecución es polinomial en el caso promedio

En otras palabras,  $ZPP$  contiene a los algoritmos *Las Vegas* que corren en tiempo polinomial esperado.

### Observación

$$ZPP = RP \cap co - RP$$

## *PP* (Probabilistic Polynomial time)

Lenguajes que tienen un algoritmo aleatorizado  $A$  tal que:

- Su tiempo de ejecución es polinomial en el peor caso
- Para cualquier entrada  $x$  en  $\Sigma^*$ :
  - $x \in L \Rightarrow Pr[A \text{ acepta } x] > \frac{1}{2}$
  - $x \notin L \Rightarrow Pr[A \text{ acepta } x] < \frac{1}{2}$

### Observación

Un algoritmo en  $PP$  es un algoritmo *Monte Carlo* que puede fallar tanto cuando  $x \in L$  como cuando  $x \notin L$ . Esto se conoce como *two-sided error*.

- Es fácil notar que como  $RP$  representa a los algoritmos *Monte Carlo one-sided error*, la repetición de un algoritmo de esta clase puede reducir arbitrariamente su probabilidad de error.
- Pero para un algoritmo  $PP$ , esto no es necesariamente cierto con una cantidad polinomial de repeticiones, ya que no sabemos qué tan lejos de  $\frac{1}{2}$  están las probabilidades:

## Proposición

Una cantidad polinomial de repeticiones de un algoritmo en  $PP$  puede no ser suficiente para reducir la probabilidad de error a  $\frac{1}{4}$ .

Y entonces?

## *BPP* (Bounded-error Probabilistic Polynomial time)

Lenguajes que tienen un algoritmo aleatorizado  $A$  tal que:

- Su tiempo de ejecución es polinomial en el peor caso
- Para cualquier entrada  $x$  en  $\Sigma^*$ :
  - $x \in L \Rightarrow \Pr[A \text{ acepta } x] \geq \frac{3}{4}$
  - $x \notin L \Rightarrow \Pr[A \text{ acepta } x] \leq \frac{1}{4}$

### Proposición

La probabilidad de error de un algoritmo en *BPP* puede reducirse a  $\frac{1}{2^n}$  con una cantidad polinomial de repeticiones.

- $P \subseteq RP \subseteq NP$
- $RP \subseteq BPP \subseteq PP$
- $PP = co - PP, BPP = co - BPP$
- $NP \subseteq PP \subseteq PSPACE$

## Ejercicio

Demuestre las propiedades anteriores.

## El problema fundamental de las estructuras de datos

Mantener conjuntos  $\{S_1, S_2, \dots\}$  de objetos pertenecientes a un universo ordenado  $U$ , de manera de soportar operaciones de búsqueda, actualización y otras eficientemente.

- Supondremos que los objetos están representados por su clave  $k$ .
- Cada objeto pertenece sólo a un conjunto, y su clave es única.

- $MAKESET(S)$ : crear un nuevo conjunto  $S$  (vacío).
- $INSERT(i, S)$ : insertar el objeto  $i$  en un conjunto  $S$ .
- $DELETE(k, S)$ : borrar el objeto indexado con clave  $k$  del conjunto  $S$ .
- $FIND(k, S)$ : retornar el objeto indexado con clave  $k$  en el conjunto  $S$ .
- **Otras:**  $JOIN(S_1, i, S_2)$ ,  $PASTE(S_1, S_2)$ ,  $SPLIT(k, S)$ .

Solución estándar: **Árboles de búsqueda binarios**

# Árboles de búsqueda binarios

- Guardamos claves en los nodos.
- Cada nodo tiene exactamente dos hijos.
- Se cumple la propiedad de ABB:

## Propiedad de ABB

Para cada nodo  $v$ , sea  $L(v)$  su hijo izquierdo y  $R(v)$  su hijo derecho:

- Si  $L(v)$  existe, entonces  $L(v).k < v.k$
  - Si  $R(v)$  existe, entonces  $R(v).k > v.k$
- 
- Las operaciones mencionadas pueden realizarse en tiempo proporcional a la altura del árbol.



- Entonces sólo debemos asegurar una altura razonable!
- Pero es muy fácil idear una secuencia de inserción malévola.
  - Basta con insertar en orden...
- Una solución: mantener un balance en el árbol con tal de asegurar una altura logarítmica en la cantidad de nodos.
  - Implica hacer rotaciones al insertar o borrar elementos.
  - Puede llegar a ser muy costoso para ciertas secuencias de operaciones.
  - Asegura tiempo de ejecución  $O(\log n)$  para las operaciones descritas.
- Otra solución: aplicar algoritmos aleatorizados!

- En cada nodo guardamos dos valores: una clave  $k(v)$  y una prioridad  $p(v)$ .
- Las claves cumplen la propiedad de ABB.
- Las prioridades cumplen la siguiente propiedad:

## Propiedad de heap

Para cada nodo  $v$ ,  $p(v) > p(u)$ , para todo hijo  $u$  de  $v$ .

## Ejercicio

Construir un treap para el conjunto

$\{(2, 13), (4, 26), (6, 19), (7, 30), (9, 14), (11, 27), (12, 22)\}$

Para un conjunto dado de pares (clave, prioridad), existe siempre un Treap?

## Teorema (Existencia y Unicidad de Treaps)

Sea  $S = \{(k_1, p_1), \dots, (k_n, p_n)\}$  un conjunto de pares clave-prioridad cualquiera tal que las claves y prioridades son todas distintas. Entonces, existe un único Treap  $T(S)$ .

**Demostración:** usamos una prueba constructiva y recursiva.

Es claro que el teorema se cumple para  $n = 0$  y  $n = 1$ . Supongamos ahora que  $n \geq 2$ , y que  $(k_1, p_1)$  tiene la mayor prioridad en  $S$ . Entonces, un treap para  $S$  puede construirse usando el primer objeto como raíz. A continuación, construimos un treap para los elementos en  $S$  con clave menor a  $k_1$  recursivamente, y todo este treap será el subárbol izquierdo de la raíz. De manera análoga se construye el treap para los demás elementos. Finalmente, es fácil ver que todo treap para  $S$  tendrá exactamente la misma composición al mirarlo desde la raíz.  $\square$

# Estructura de un treap

- La estructura de un treap depende de las prioridades relativas de los pares del conjunto.
- De hecho, podemos forzar su estructura eligiendo las prioridades convenientemente.
- Entonces, si somos capaces de generar un conjunto de prioridades adecuado, podemos obtener un treap de profundidad baja... y resolver el problema fundamental de las estructuras de datos!
  - Alguna idea?
  - Prioridades aleatorias!

- En un *random treap*, las prioridades se eligen aleatoriamente de una distribución que asegure no repetición de prioridades.
- Como el ordenamiento de las prioridades será completamente independiente del de las claves, la estructura del treap permanecerá balanceada, y tendrá una profundidad esperada de  $O(\log n)$ .
- Además, como la elección de las prioridades se mantiene “escondida”, es imposible para un adversario invocar una secuencia de operaciones que desbalancee el treap.
- Suena lindo, pero se puede demostrar?
  - **Sí**, pero necesitamos una herramienta: los **Juegos de Mulmuley**.

## Participantes:

- **Jugadores:**  $P = \{P_1, \dots, P_p\}$
- **Stoppers:**  $S = \{S_1, \dots, S_s\}$
- **Gatilladores:**  $T = \{T_1, \dots, T_t\}$
- **Espectadores:**  $B = \{B_1, \dots, B_b\}$

## Reglas:

- El conjunto  $P \cup S$  se obtiene de un universo totalmente ordenado.
- Todos los jugadores son menores que todos los *stoppers*: para todo  $i, j$ ,  $P_i < S_j$ .
- Los conjuntos son disjuntos a pares.

Dependiendo de los personajes que participan, se definen cuatro juegos, pero primero veamos una propiedad útil.

## Propiedad

Sea  $H_k = \sum_{i=1}^k \frac{1}{i}$  el k-ésimo número armónico.

Se cumple que  $\sum_{k=1}^n H_k = (n+1)H_{n+1} - (n+1)$

## Recordatorio

$$H_k = \ln k + O(1)$$

## Juego A

- Se comienza con el conjunto de personajes  $X = P \cup B$ .
- El juego consiste en sacar personajes de  $X$  sin reemplazo, hasta que  $X$  queda vacío.
- Cada personaje se elige aleatoriamente de manera uniforme entre los que quedan en  $X$ .
- Sea  $V$  una variable aleatoria, definida como el número de veces que un jugador  $P_i$  es elegido de manera tal que es mayor que todos los jugadores elegidos anteriormente.
- Definimos el **valor** del juego  $A_p$  como  $E[V]$ .



## Lema

Para todo  $p \geq 0$ ,  $A_p = H_p$ .

**Demostración:** Suponemos que el conjunto de jugadores está ordenado como  $P_1 > P_2 > \dots > P_p$ .

- Notemos que los espectadores son absolutamente irrelevantes: el valor del juego no está influenciado por la cantidad de espectadores. Podemos asumir entonces que la cantidad de espectadores es  $b = 0$ .
- Sea  $P_i$  el primer jugador obtenido. Tenemos entonces que el valor esperado del juego es  $1 + A_{i-1}$ . Esto es porque los demás jugadores ( $P_{i+1}, \dots, P_p$ ) ya no pueden aportar al valor del juego, y en la práctica se convierten en espectadores.

# Juegos de Mulmuley: Juego A

- Ya que  $i$  distribuye uniformemente sobre  $\{1, \dots, p\}$ , obtenemos la recurrencia  $A_p = \sum_{i=1}^p \frac{1+A_{i-1}}{p} = 1 + \sum_{i=1}^p \frac{A_{i-1}}{p}$ .
- Reacomodando los términos, y sabiendo que  $A_0 = 1$ , tenemos que  $\sum_{i=1}^{p-1} A_i = pA_p - p$ .
- Finalmente, usando la propiedad de los números armónicos enunciada anteriormente, concluimos que  $A_p = H_p \square$

## Juego C

- Se comienza con el conjunto de personajes  $X = P \cup B \cup S$ .
- El juego se desarrolla igual que antes, considerando a los *stoppers* como jugadores.
- La diferencia radica en que una vez que se elige el primer stopper, se acaba el juego.
- Dado que los stoppers son todos mayores que los jugadores, el primer stopper siempre agregará 1 al valor del juego.
- Definimos el **valor** del juego como  $C_p^s = E[V + 1] = 1 + E[V]$ , con  $V$  definida como en el juego  $A$ .

## Lema

Para todo  $p, s \geq 0$ ,  $C_p^s = 1 + H_{s+p} - H_s$ .

**Demostración:** Asumimos el mismo orden de antes ( $P_1 > P_2 > \dots > P_p$ ) y que la cantidad de espectadores es 0.

- Si la primera jugada es un stopper, el valor del juego es 1. La probabilidad de que esto ocurra es  $\frac{s}{s+p}$ .
- Si la primera jugada es un jugador  $P_i$ , el valor del juego es  $1 + C_{i-1}^s$ . Esto pasa con probabilidad  $\frac{1}{s+p}$ .

Así, obtenemos la siguiente recurrencia:

$$C_p^s = \left(\frac{s}{s+p} \times 1\right) + \left(\frac{1}{s+p} \times \sum_{i=1}^p (1 + C_{i-1}^s)\right)$$

# Juegos de Mulmuley: Juego C

Reordenando y teniendo en cuenta que  $C_0^s = 1$ :

$$C_p^s = \frac{s+p+1}{s+p} + \frac{\sum_{i=1}^{p-1} C_i^s}{s+p}$$

y equivalentemente:

$$\sum_{i=1}^{p-1} C_i^s = (s+p)C_p^s - (s+p+1)$$

Entonces, usando nuevamente la propiedad de los números armónicos, concluimos que la solución de la recurrencia es

$$C_p^s = 1 + H_{s+p} - H_s \square$$

## Juegos D y E

- Muy similares a los juegos A y C.
- La diferencia es que los conjuntos de personajes son  $X = P \cup B \cup T$  y  $X = P \cup B \cup S \cup T$  respectivamente.
- El conteo empieza después de sacar el primer gatillador.
- Entonces, un jugador o stopper contribuye a  $V$  si y sólo si son sacados después de un gatillador, antes de cualquier stopper y si es mayor que todos los jugadores escogidos previamente.

# Juegos de Mulmuley: Juegos D y E

Sean  $D_p^t$  y  $E_p^{s,t}$  los valores esperados de los juegos D y E respectivamente.

## Lema

Para todo  $p, t \geq 0$ ,  $D_p^t = H_p + H_t - H_{p+t}$ .

## Lema

Para todo  $p, s, t \geq 0$ ,  $E_p^{s,t} = \frac{t}{s+t} + (H_{s+p} - H_s) - (H_{s+p+t} - H_{s+t})$ .

## Ejercicio

Demuestre los lemas anteriores.

Para aplicar los Juegos de Mulmuley al análisis de desempeño de *random treaps*, será útil la siguiente propiedad:

## Propiedad (Carencia de memoria)

- Sea un *random treap* obtenido tras insertar los elementos de un conjunto  $S$  en un treap inicialmente vacío.
- Como las prioridades aleatorias de los elementos en  $S$  se eligen de manera independiente, podemos asumir que se asignan antes de iniciar la inserción de ellos.
- Una vez que hemos fijado las prioridades, el teorema de Existencia y Unicidad de treaps implica que existe un único treap  $T$  para los elementos de  $S$  con las prioridades asignadas.



## Propiedad (Carencia de memoria)

- Entonces, el orden en que se insertan los elementos de  $S$  no altera la estructura del treap  $T$ .
- Luego, sin pérdida de generalidad, podemos asumir que **los elementos de  $S$  fueron insertados en  $T$  en orden decreciente respecto a la prioridad.**
- Esto significa que todas las inserciones se realizan en las hojas, y que además no necesitamos rotaciones para conservar la propiedad de treap.

Sea la **profundidad** de un nodo  $x$  en un treap su distancia a la raíz, denotada como  $depth(x)$ .

Sea el **rango** de un elemento en un conjunto su posición en un orden creciente del conjunto.

## Lema

Sea  $T$  un random treap para un conjunto  $S$  con  $n$  elementos. Dado un elemento  $x \in S$  con rango  $k$ :

$$E[depth(x)] = H_k + H_{n-k+1} - 1$$

**Demostración:** Sean los conjuntos

$$S^- = \{y \in S \mid y \leq x\}, S^+ = \{y \in S \mid y \geq x\}$$

Dado que  $x$  tiene rango  $k$ , es claro que

$$|S^-| = k, |S^+| = n - k + 1$$

Sea  $Q_x \subseteq S$  el conjunto de elementos que están guardados en nodos en el camino desde la raíz de  $T$  hasta el nodo que contiene a  $x$ ; en otras palabras,  $Q_x$  contiene a los ancestros de  $x$  en  $T$ . Sean además

$$Q_x^- = S^- \cap Q_x, Q_x^+ = S^+ \cap Q_x$$

La idea de la demostración es la siguiente: supongamos que

$$E[|Q_x^-|] = H_k$$

Por simetría, el tamaño esperado de  $Q_x^+$  será  $H_{n-k+1}$ . Esto implicará que el largo esperado del camino de la raíz a  $x$  será

$$H_k + H_{n-k+1} - 1$$

como queremos demostrar, dado que  $Q_x^- \cap Q_x^+ = \{x\}$ .

Luego, sólo nos basta demostrar nuestra suposición inicial!

**PD:**  $E[|Q_x^-|] = H_k$

- Tomemos un ancestro  $y \in Q_x^-$  de  $x$ . Por carencia de memoria,  $y$  debió haber sido insertado antes que  $x$ , y sus prioridades satisfacen  $p_x > p_y$ .
- Como  $y < x$ ,  $x$  debe estar en el sub-árbol derecho de  $y$ . De hecho, todo elemento  $z$  tal que  $y < z < x$  está en el sub-árbol derecho de  $y$ .
- En otras palabras,  $y$  es ancestro de cada nodo que contenga un elemento con clave entre  $y$  y  $x$ .
- Usando el orden de inserción que asumimos anteriormente, deducimos que todo elemento cuya clave esté entre  $y$  y  $x$  debió haber sido insertado después de  $y$ , y luego tiene menor prioridad que  $y$ .

- El razonamiento anterior es equivalente a decir que un elemento  $y \in S^-$  es un ancestro de  $x$  (o pertenece a  $Q_x^-$ ) si y sólo si era el elemento con mayor clave en  $S^-$  al momento de su inserción.
- Dado que el orden de inserción está determinado por el orden de las prioridades, y éstas distribuyen uniformemente, podemos decir que el orden de inserción está dado por un muestreo sin reemplazo del conjunto  $S$ .
- Entonces, podemos ver que **la distribución de  $|Q_x^-|$  es la misma que la del valor del Juego de Mulmuley  $\mathbf{A}$** , haciendo

$$P = S^- \text{ y } B = S \setminus S^-$$

- Finalmente, como  $|S^-| = k$ , concluimos que  $E[|Q_x^-|] = H_k \square$

# Análisis de Treaps

Ya dijimos que el tiempo que toman las operaciones *FIND*, *INSERT* y *DELETE* es proporcional a la altura del treap. Sin embargo, podemos establecer algo más fuerte: Sea la **columna derecha** de un árbol el camino obtenido al empezar en la raíz y moverse repetidamente hacia la derecha, hasta llegar a una hoja. Se define la **columna izquierda** similarmente.

## Proposición

El número de rotaciones necesarias durante la eliminación de un nodo  $v$  es igual a la suma de los largos de la columna izquierda del sub-árbol derecho y de la columna derecha del sub-árbol izquierdo de  $v$ .

## Ejercicio

Demuestre la proposición y enuncie un resultado equivalente para la operación *INSERT*.

Sea ahora  $L_x$  el largo de la columna izquierda del sub-árbol derecho de un elemento  $x$  en un treap, y  $R_x$  el largo de la columna derecha del sub-árbol izquierdo de  $x$ .

## Lema

Sea  $T$  un random treap para un conjunto  $S$  con  $n$  elementos. Dado un elemento  $x \in S$  con rango  $k$ :

$$E[R_x] = 1 - \frac{1}{k}$$

$$E[L_x] = 1 - \frac{1}{n-k+1}$$



**Demostración:** demostraremos que la distribución de  $R_x$  es la misma que la del valor del Juego de Mulmuley D, tomando

$$P = S^- \setminus \{x\}, T = \{x\}, B = S^+ \setminus \{x\}$$

con  $S^-$  y  $S^+$  definidos como antes.

Como  $p = k - 1$ ,  $t = 1$  y  $b = n - k$ , del lema para el valor del Juego D obtenemos que

$$E[R_x] = D_{k-1}^1 = H_{k-1} + H_1 - H_k = 1 - \frac{1}{k}$$

Para relacionar el largo de la columna derecha del sub-árbol izquierdo de  $x$  al Juego D, hacemos la siguiente proposición:

## Proposición

Un elemento  $z < x$  está en la columna derecha del sub-árbol izquierdo de  $x$  si y sólo si  $z$  es insertado después de  $x$ , y todos los elementos cuyo valor está entre  $z$  y  $x$  son insertados después de  $z$ .

## Demostración:

( $\Leftarrow$ ): Tomemos el camino recorrido por el procedimiento de inserción de  $z$ , al localizar la hoja donde  $z$  será insertado. Este camino debe pasar por el nodo que contiene a  $x$ , dado que la única manera de distinguir entre  $z$  y  $x$  es comparándolos con un elemento que esté entre ellos, los cuales son todos insertados después de  $z$ .

Como  $z$  es menor que  $x$  y es insertado después que  $x$ , debe estar en el sub-árbol izquierdo de  $x$ . Además, dado que todos los elementos en el sub-árbol izquierdo de  $x$  son menores que  $x$ , y  $z$  es el mayor de ellos al momento de su inserción,  $z$  debe estar en la columna derecha de este sub-árbol.

( $\Rightarrow$ ): Dado que  $z$  está en el sub-árbol izquierdo de  $x$ , debe haber sido insertado después de  $x$  y ser menor que  $x$ . Además, todos los elementos con valor entre  $z$  y  $x$  deben estar en el sub-árbol izquierdo de  $x$ , y como  $z$  está en la columna derecha del sub-árbol, estos elementos deben haber sido insertados después de  $z$ .  $\square$

## Ejercicio

Demostrar la segunda parte del lema.

Finalmente, usando todos los lemas y proposiciones enunciadas, es fácil demostrar el siguiente teorema:

## Teorema (Desempeño de un *Random Treap*)

- 1 El tiempo esperado para las operaciones *FIND*, *INSERT* y *DELETE* en un random treap  $T$  es  $O(\log n)$ .
- 2 El número esperado de rotaciones requeridas durante una inserción o eliminación es a lo más 2.
- 3 El tiempo esperado para las operaciones *JOIN*, *PASTE* y *SPLIT* que involucren conjuntos  $S_1$  y  $S_2$  de tamaño  $n$  y  $m$  respectivamente es  $O(\log n + \log m)$ .