

Teorema. *Sejam X e Y v.a.'s independentes. Então $E[XY] = E[X] \cdot E[Y]$.*

BucketSort

Prof. André Vignatti

Suposição: entrada com distribuição aleatória uniforme dos elementos em $[0, 1)$.

Idéia:

- Divida $[0, 1)$ em n baldes de tamanhos iguais.
- Distribua os n valores de entrada nos baldes.
- Ordene cada balde.
- Percorra os baldes em ordem, listando os elementos em cada um.

BucketSort(A, n)

seja $B[0..n - 1]$ um novo vetor;

for $i = 1$ **to** $n - 1$ **do**

 faça $B[i]$ uma lista vazia


for $i = 1$ **to** n **do**

 insira $A[i]$ na lista $B[\lfloor n \cdot A[i] \rfloor]$

for $i = 1$ **to** $n - 1$ **do**

 ordene a lista $B[i]$ com InsertionSort

return a concatenação das listas $B[0], B[1], \dots, B[n - 1]$ em ordem



Corretude

Considere $A[i]$ e $A[j]$. Assuma sem perda de generalidade que $A[i] \leq A[j]$. Então $\lfloor n \cdot A[i] \rfloor \leq \lfloor n \cdot A[j] \rfloor$. Então $A[i]$ é colocado no mesmo balde que $A[j]$ ou em um balde com um índice menor.

- Se for no mesmo balde, a ordenação por inserção corrige.
- Se for no balde anterior, a concatenação corrige.

Tempo Esperado

- Todas as linhas do algoritmo, exceto a ordenação por inserção, leva $\Theta(n)$.
- Se cada balde recebe um número constante de elementos: $O(1)$ para ordenar cada balde $\Rightarrow O(n)$ para ordenar tudo.
- Esperamos que cada balde tenha poucos elementos, já que a média é 1 elemento por balde.
- Mas precisamos fazer uma análise cuidadosa.

Defina uma variável aleatória:

- n_i : número de elementos colocados no balde i .

Como o InsertionSort executa em tempo quadrático, então o tempo do Bucket-Sort é:

$$T(n) = \Theta(n) + \sum_{i=0}^{n-1} O(n_i^2).$$

E o valor esperado é

$$\begin{aligned} E[T(n)] &= E \left[\Theta(n) + \sum_{i=0}^{n-1} O(n_i^2) \right] \\ &= \Theta(n) + \sum_{i=0}^{n-1} E[O(n_i^2)] \quad (\text{linearidade da esperanca}) \\ &= \Theta(n) + \sum_{i=0}^{n-1} O(E[n_i^2]) \quad (E[aX] = aE[X]) \end{aligned}$$

Teorema. $E[n_i^2] = 2 - 1/n$ para $i = 0, \dots, n - 1$.

Demonstração. Seja X_{ij} v.a. tal que $X_{ij} = 1$ se $A[j]$ cai no balde i , e $X_{ij} = 0$ c.c. Desta forma,

$$n_i = \sum_{j=1}^n X_{ij}.$$

Assim,

$$\begin{aligned}
\mathbb{E}[n_i^2] &= \mathbb{E} \left[\left(\sum_{j=1}^n X_{ij} \right)^2 \right] \\
&= \mathbb{E} \left[\sum_{j=1}^n \sum_{k=1}^n X_{ij} X_{ik} \right] \\
&= \mathbb{E} \left[\sum_{j=1}^n X_{ij}^2 + \sum_{1 \leq j \leq n} \sum_{\substack{1 \leq k \leq n \\ k \neq j}} X_{ij} X_{ik} \right] \\
&= \sum_{j=1}^n \mathbb{E}[X_{ij}^2] + \sum_{1 \leq j \leq n} \sum_{\substack{1 \leq k \leq n \\ k \neq j}} \mathbb{E}[X_{ij} X_{ik}].
\end{aligned}$$

Note que $\Pr(X_{ij} = 1) = \frac{1}{n}$, portanto

$$\mathbb{E}[X_{ij}^2] = 1^2 \cdot \Pr(X_{ij}^2 = 1) + 0^2 \cdot \Pr(X_{ij}^2 = 0) = 1^2 \cdot \Pr(X_{ij} = 1) = \frac{1}{n}.$$

Quando $k \neq j$, as v.a. X_{ij} e X_{ik} são independentes, então

$$\mathbb{E}[X_{ij} X_{ik}] = \mathbb{E}[X_{ij}] \mathbb{E}[X_{ik}] = \frac{1}{n} \cdot \frac{1}{n} = \frac{1}{n^2}.$$

□

Substituindo os valores encontrados,

$$\begin{aligned}
\mathbb{E}[n_i^2] &= \sum_{j=1}^n \frac{1}{n} + \sum_{1 \leq j \leq n} \sum_{\substack{1 \leq k \leq n \\ k \neq j}} \frac{1}{n^2} \\
&= n \cdot \frac{1}{n} + n(n-1) \cdot \frac{1}{n^2} \\
&= 1 + \frac{n-1}{n} \\
&= 2 - \frac{1}{n}.
\end{aligned}$$

Portanto,

$$\begin{aligned}
\mathbb{E}[T(n)] &= \Theta(n) + \sum_{i=0}^{n-1} O(2 - 1/n) \\
&= \Theta(n) + O(n) \\
&= \Theta(n).
\end{aligned}$$

Lembrando: não é uma ordenação por comparação.

- Esta é uma análise probabilística - usamos probabilidade para analisar um algoritmo cujo tempo de execução depende da distribuição de entradas.
- Diferente de um algoritmo aleatorizado, onde usamos a aleatorização para impor uma distribuição.