

# La propiedad central

Dado  $i \in \{1, \dots, s\}$ , para la iteración  $i$  del algoritmo sean:

- ▶  $x_i, N_i$  los valores de las variables  $x$  y  $N$  al principio de la iteración
  - ▶ Tenemos que  $x_1 = x$  y  $N_1 = 1$
- ▶  $w_i, \alpha_i$  los valores de las variables  $w$  y  $\alpha$  calculados en la iteración

## Propiedad de aproximación

Para cada  $i \in \{1, \dots, s\}$ :

$$\frac{\alpha_i}{1 + \frac{\varepsilon}{2m}} \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot \alpha_i$$

# Usando la propiedad de aproximación

Tenemos que:

$$\begin{aligned}
 \Pr\left(\frac{N_R(x)}{(1+\varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1+\varepsilon) \cdot N_R(x)\right) &= \\
 \Pr\left(\frac{N_R(x)}{(1+\varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1+\varepsilon) \cdot N_R(x) \mid \text{propiedad de aproximación}\right) &\cdot \\
 \Pr(\text{propiedad de aproximación}) &+ \\
 \Pr\left(\frac{N_R(x)}{(1+\varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1+\varepsilon) \cdot N_R(x) \mid \overline{\text{propiedad de aproximación}}\right) &\cdot \\
 \Pr(\overline{\text{propiedad de aproximación}}) &\geq \\
 \Pr\left(\frac{N_R(x)}{(1+\varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1+\varepsilon) \cdot N_R(x) \mid \text{propiedad de aproximación}\right) &\cdot \\
 \Pr(\text{propiedad de aproximación}) &
 \end{aligned}$$

# Usando la propiedad de aproximación

Por lo tanto, para demostrar que **EAR** es un FPRAS para  $R$  basta acotar inferiormente la siguiente probabilidad:

$$\Pr\left(\frac{N_R(x)}{(1 + \varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1 + \varepsilon) \cdot N_R(x) \mid \text{propiedad de aproximación}\right) \cdot \Pr(\text{propiedad de aproximación})$$

Primero vamos a demostrar que la propiedad de aproximación es suficiente para tener una buena aproximación de  $N_R(x)$

- Después de esto vamos a acotar inferiormente la probabilidad de que la propiedad de aproximación se cumpla

# La propiedad de aproximación es suficiente

Definimos  $x_{s+1}$  y  $N_{s+1}$  como los valores de las variables  $x$  y  $N$  al final de la iteración  $s$  del algoritmo.

- ▶ Tenemos que  $g(x_{s+1}) = 0$ ,  $N_R(x_{s+1}) = 1$  y el valor retornado por el algoritmo es  $N_{s+1}$ 
  - ▶ ¿Por qué?

Dado  $i \in \{1, \dots, s\}$ , tenemos que:

$$\begin{aligned}x_{i+1} &= \psi(x_i, w_i) \\ N_R(x_{i+1}) &= |\text{Ext}_R(x_i, w_i)| \\ N_{i+1} &= \frac{1}{\alpha_i} \cdot N_i\end{aligned}$$

# La propiedad de aproximación es suficiente

Además, tenemos que:

$$\begin{aligned}\frac{\alpha_i}{\left(1 + \frac{\varepsilon}{2m}\right)} &\leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot \alpha_i \\ \Rightarrow \frac{N_R(x_i)}{\left(1 + \frac{\varepsilon}{2m}\right)} &\leq \frac{|\text{Ext}_R(x_i, w_i)|}{\alpha_i} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot N_R(x_i) \\ \Rightarrow \frac{N_R(x_i) \cdot N_i}{\left(1 + \frac{\varepsilon}{2m}\right)} &\leq |\text{Ext}_R(x_i, w_i)| \cdot \frac{N_i}{\alpha_i} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot N_R(x_i) \cdot N_i \\ \Rightarrow \frac{N_R(x_i) \cdot N_i}{\left(1 + \frac{\varepsilon}{2m}\right)} &\leq N_R(x_{i+1}) \cdot N_{i+1} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot N_R(x_i) \cdot N_i\end{aligned}$$

Así, la cantidad  $N_R(x_i) \cdot N_i$  es *casi* una invariante del ciclo **while**

## La propiedad de aproximación es suficiente

Suponiendo que la propiedad de aproximación es cierta concluimos que:

$$\frac{N_R(x_1) \cdot N_1}{\left(1 + \frac{\varepsilon}{2m}\right)^s} \leq N_R(x_{s+1}) \cdot N_{s+1} \leq \left(1 + \frac{\varepsilon}{2m}\right)^s \cdot N_R(x_1) \cdot N_1$$

Por lo tanto, dado que  $s \leq m$  tenemos que:

$$\frac{N_R(x_1) \cdot N_1}{\left(1 + \frac{\varepsilon}{2m}\right)^m} \leq N_R(x_{s+1}) \cdot N_{s+1} \leq \left(1 + \frac{\varepsilon}{2m}\right)^m \cdot N_R(x_1) \cdot N_1$$

## Algunas propiedades de $N_R(x_i) \cdot N_i$

Dado que  $x_1 = x$  y  $N_1 = 1$ , tenemos que  $N_R(x) = N_R(x_1) \cdot N_1$

- Recuerde que queremos calcular  $N_R(x)$

Dado que  $N_R(x_{s+1}) = 1$ , tenemos que  $N_R(x_{s+1}) \cdot N_{s+1} = N_{s+1}$

- Además, sabemos que **EAR**( $x, \varepsilon$ ) =  $N_{s+1}$

# La propiedad de aproximación es suficiente: conclusión

Juntando los resultados anteriores obtenemos:

$$\frac{N_R(x)}{\left(1 + \frac{\varepsilon}{2m}\right)^m} \leq \mathbf{EAR}(x, \varepsilon) \leq \left(1 + \frac{\varepsilon}{2m}\right)^m \cdot N_R(x)$$

Dado que  $\varepsilon \in (0, 1)$ , tal como el caso de #KS obtenemos:

$$\left(1 + \frac{\varepsilon}{2m}\right)^m \leq e^{\frac{\varepsilon}{2}} \leq \varepsilon + 1$$

## Ejercicio

Demuestre que  $e^{\frac{\varepsilon}{2}} \leq \varepsilon + 1$  considerando que  $0 < \varepsilon < 1$  y el intervalo donde la función  $f(x) = e^{\frac{x}{2}} - x - 1$  es negativa.

# La propiedad de aproximación es suficiente: conclusión

Así, suponiendo que la propiedad de aproximación se cumple obtenemos:

$$\frac{N_R(x)}{(1 + \varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1 + \varepsilon) \cdot N_R(x)$$

Vale decir, hemos demostrado que:

$$\Pr\left(\frac{N_R(x)}{(1 + \varepsilon)} \leq \mathbf{EAR}(x, \varepsilon) \leq (1 + \varepsilon) \cdot N_R(x) \mid \begin{array}{l} \text{propiedad de aproximación} \end{array}\right) = 1$$

De esta forma, para terminar la demostración tenemos que demostrar:

$$\Pr\left(\text{propiedad de aproximación}\right) \geq \frac{3}{4}$$

# Acotando inferiormente $\Pr(\text{propiedad de aproximación})$

Fije  $i \in \{1, \dots, s\}$

- ▶  $i$  corresponde a una iteración de **EAR**

Para cada  $u \in \Sigma^{\sigma(x_i)}$  definimos la variable aleatoria:

$$X_u = \frac{|\{j \in \{1, \dots, t\} \mid \exists z \in \Sigma^* : y_j = uz\}|}{t}$$

$X_u$  es un promedio de  $t$  variables aleatorias que toman valor 0 ó 1, las cuales denotamos como  $X_{j,u}$  para  $j \in \{1, \dots, t\}$

- ▶  $X_{j,u}(y_j) = 1$  si  $y_j = uz$  para algún  $z \in \Sigma^*$ , y  $X_{j,u}(y_j) = 0$  en otro caso

Vale decir, tenemos que  $X_u = \frac{1}{t} \sum_{j=1}^t X_{j,u}$

## Acotando inferiormente $\Pr(\text{propiedad de aproximación})$

Tenemos que:

$$\mathbf{Var}[X_u] = \mathbf{Var}\left[\frac{1}{t} \sum_{j=1}^t X_{j,u}\right] = \frac{1}{t^2} \sum_{j=1}^t \mathbf{Var}[X_{j,u}] \leq \frac{1}{t^2} \sum_{j=1}^t 1 = \frac{1}{t}$$

Dado que  $t = \lceil 180 \cdot (|x|^c + d)^3 \cdot m^3 \cdot \varepsilon^{-2} \rceil$ , por la desigualdad de Chebyshev concluimos que:

$$\begin{aligned} \Pr\left(|X_u - \mathbf{E}[X_u]| \geq \frac{\varepsilon}{6 \cdot (|x|^c + d) \cdot m}\right) &\leq \frac{36 \cdot (|x|^c + d)^2 \cdot m^2 \cdot \mathbf{Var}[X_u]}{\varepsilon^2} \\ &\leq \frac{36 \cdot (|x|^c + d)^2 \cdot m^2}{\varepsilon^2 \cdot t} \\ &\leq \frac{36 \cdot (|x|^c + d)^2 \cdot m^2}{\varepsilon^2 \cdot 180 \cdot (|x|^c + d)^3 \cdot m^3 \cdot \varepsilon^{-2}} \\ &= \frac{1}{5 \cdot (|x|^c + d) \cdot m} \end{aligned}$$

## Definiendo $\alpha_i$ en términos de las variables aleatorias $X_u$

El valor de cada variable aleatoria  $X_u$  es una función de las variables  $y_1, \dots, y_t$

- Podemos entonces hablar de  $X_u(y_1, \dots, y_t)$

De la misma forma, el valor de la variable aleatoria  $\alpha_i$  es una función de  $y_1, \dots, y_t$ , y podemos hablar de  $\alpha_i(y_1, \dots, y_t)$

## Definiendo $\alpha_i$ en términos de las variables aleatorias $X_u$

Suponga que  $v$  es el valor de  $w_i$ . Si los valores de las variables  $y_1, \dots, y_t$  en la iteración  $i$  son  $a_1, \dots, a_t$ , respectivamente, entonces tenemos que:

$$\alpha_i(a_1, \dots, a_t) = X_v(a_1, \dots, a_t)$$

Además, en general tenemos que:

$$\alpha_i(y_1, \dots, y_t) = \max_{u \in \Sigma^{\sigma(x_i)}} X_u(y_1, \dots, y_t)$$

Es importante notar que **no** podemos concluir que:

$$\alpha_i(y_1, \dots, y_t) = X_v(y_1, \dots, y_t),$$

dado que  $v$  es un string **fijo** calculado en la iteración  $i$

No podemos concluir que  $\alpha_i(y_1, \dots, y_t) = X_v(y_1, \dots, y_t)$

Suponga que ejecutamos el algoritmo nuevamente obteniendo  $v'$  como el valor de  $w_i$

- Además, suponga que los valores de las variables  $y_1, \dots, y_t$  en la iteración  $i$  de esta nueva ejecución son  $b_1, \dots, b_t$ , respectivamente.

Sabemos que  $\alpha_i(b_1, \dots, b_t) = X_{v'}(b_1, \dots, b_t)$

Pero si  $v \neq v'$  y  $X_v(b_1, \dots, b_t) < X_{v'}(b_1, \dots, b_t)$ , entonces tenemos que:

$$\alpha_i(b_1, \dots, b_t) \neq X_v(b_1, \dots, b_t)$$

## Acotando superiormente $\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \delta)$

Queremos entender cuán cerca está  $\alpha_i$  de  $\mathbf{E}[X_{w_i}]$

- Vale decir, queremos acotar superiormente  $\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \delta)$

Dado que  $\alpha_i = \max_{u \in \Sigma^{\sigma(x_i)}} X_u$ , no podemos utilizar la desigualdad de Chebyshev para acotar superiormente  $\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \delta)$

- ¿Por qué?

## Acotando superiormente $\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \delta)$

Si  $|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \delta$  en la iteración  $i$ , entonces se debe tener que  $|X_{w_i} - \mathbf{E}[X_{w_i}]| \geq \delta$

- Y si esperamos que esto se cumpla en la iteración  $i$  de cada ejecución de **EAR**, entonces en cada ejecución debe ser posible encontrar  $u \in \Sigma^{\sigma(x_i)}$  tal que  $|X_u - \mathbf{E}[X_u]| \geq \delta$

Por lo tanto, tenemos que:

$$\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \delta) \leq \Pr\left(\bigvee_{u \in \Sigma^{\sigma(x_i)}} |X_u - \mathbf{E}[X_u]| \geq \delta\right)$$

# Acotando superiormente $\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \frac{\varepsilon}{6 \cdot (|x|^c + d) \cdot m})$

Utilizando la conclusión de la transparencia anterior:

$$\begin{aligned}
 \Pr\left(|\alpha_i - \mathbf{E}[X_{w_i}]| \geq \frac{\varepsilon}{6 \cdot (|x|^c + d) \cdot m}\right) &\leq \\
 \Pr\left(\bigvee_{u \in \Sigma^{\sigma(x_i)}} \left[|X_u - \mathbf{E}[X_u]| \geq \frac{\varepsilon}{6 \cdot (|x|^c + d) \cdot m}\right]\right) &\leq \\
 \sum_{u \in \Sigma^{\sigma(x_i)}} \Pr\left(|X_u - \mathbf{E}[X_u]| \geq \frac{\varepsilon}{6 \cdot (|x|^c + d) \cdot m}\right) &\leq \\
 \sum_{u \in \Sigma^{\sigma(x_i)}} \frac{1}{5 \cdot (|x|^c + d) \cdot m} &= \\
 \frac{1}{5 \cdot (|x|^c + d) \cdot m} \cdot |\Sigma|^{\sigma(x_i)} &\leq \\
 \frac{1}{5 \cdot (|x|^c + d) \cdot m} \cdot (|x_i|^c + d) &= \frac{1}{5m} \cdot \left(\frac{|x_i|^c + d}{|x|^c + d}\right) \leq \frac{1}{5m}
 \end{aligned}$$

¿Por qué **EAR** elige el prefijo de largo  $\sigma(x)$  más común en  $\{y_1, \dots, y_t\}$ ?

Como  $w_i$  se elige como el prefijo de largo  $\sigma(x_i)$  más común en  $\{y_1, \dots, y_t\}$ , sabemos que:

$$\begin{aligned} \alpha_i &= \frac{|\{j \in \{1, \dots, t\} \mid y_j \in \text{Ext}_R(x_i, w_i)\}|}{t} \geq \frac{t}{|\Sigma|^{\sigma(x_i)}} \cdot \frac{1}{t} = \\ &\frac{1}{|\Sigma|^{\sigma(x_i)}} \geq \frac{1}{|x_i|^c + d} \geq \frac{1}{|x|^c + d} \end{aligned}$$

Concluimos entonces que:

$$\begin{aligned} \Pr\left(|\alpha_i - \mathbf{E}[X_{w_i}]| \leq \alpha_i \cdot \frac{\varepsilon}{6m}\right) &\geq \Pr\left(|\alpha_i - \mathbf{E}[X_{w_i}]| \leq \frac{\varepsilon}{6 \cdot (|x|^c + d) \cdot m}\right) \\ &\geq 1 - \frac{1}{5m} \end{aligned}$$

## Dos desigualdades útiles

Tenemos que  $1 + \frac{\varepsilon}{5m} \geq 1 + \frac{\varepsilon}{6m}$

Por otra parte, para  $\varepsilon \in (0, 1)$  también se tiene que:

$$\frac{1}{1 + \frac{\varepsilon}{5m}} \leq 1 - \frac{\varepsilon}{6m},$$

puesto que  $m \geq 1$  y:

$$\begin{aligned} \frac{1}{1 + \frac{\varepsilon}{5m}} \leq 1 - \frac{\varepsilon}{6m} &\Leftrightarrow \frac{5m}{5m + \varepsilon} \leq \frac{6m - \varepsilon}{6m} \\ &\Leftrightarrow 30 \cdot m^2 \leq 30 \cdot m^2 + 6 \cdot m \cdot \varepsilon - 5 \cdot m \cdot \varepsilon - \varepsilon^2 \\ &\Leftrightarrow \varepsilon^2 \leq m \cdot \varepsilon \\ &\Leftrightarrow \varepsilon \leq m \end{aligned}$$

## Una cota inferior para $\Pr(|\alpha_i - \mathbf{E}[X_{w_i}]| \leq \alpha_i \cdot \frac{\varepsilon}{6m})$

Usando todas las desigualdades anteriores concluimos que:

$$\begin{aligned} \Pr\left(\frac{1}{(1 + \frac{\varepsilon}{5m})} \cdot \alpha_i \leq \mathbf{E}[X_{w_i}] \leq \left(1 + \frac{\varepsilon}{5m}\right) \cdot \alpha_i\right) &\geq \\ \Pr\left(\left(1 - \frac{\varepsilon}{6m}\right) \cdot \alpha_i \leq \mathbf{E}[X_{w_i}] \leq \left(1 + \frac{\varepsilon}{6m}\right) \cdot \alpha_i\right) &= \\ \Pr\left(|\alpha_i - \mathbf{E}[X_{w_i}]| \leq \alpha_i \cdot \frac{\varepsilon}{6m}\right) &\geq \\ 1 - \frac{1}{5m} \end{aligned}$$

## Acotando $\mathbf{E}[X_{w_i}]$

Por definición de  $X_{w_i}$ , se tiene que:

$$\begin{aligned}\mathbf{E}[X_{w_i}] &= \mathbf{E}\left[\frac{1}{t} \sum_{j=1}^t X_{j,w_i}\right] \\&= \frac{1}{t} \sum_{j=1}^t \mathbf{E}[X_{j,w_i}] \\&= \frac{1}{t} \sum_{j=1}^t \left(1 \cdot \mathbf{Pr}(X_{j,w_i} = 1) + 0 \cdot \mathbf{Pr}(X_{j,w_i} = 0)\right) \\&= \frac{1}{t} \sum_{j=1}^t \sum_{y \in \text{Ext}_R(x_i, w_i)} \mathbf{Pr}\left(\mathcal{G}\left(x_i, \frac{\varepsilon}{4m}\right) = y\right) \\&= \sum_{y \in \text{Ext}_R(x_i, w_i)} \mathbf{Pr}\left(\mathcal{G}\left(x_i, \frac{\varepsilon}{4m}\right) = y\right)\end{aligned}$$

## Acotando $\mathbf{E}[X_{w_i}]$

Como  $\mathcal{G}$  es un FPAUG, tenemos que:

$$\frac{1}{\left(1 + \frac{\varepsilon}{4m}\right)} \cdot \frac{1}{N_R(x_i)} \leq \Pr\left(\mathcal{G}\left(x_i, \frac{\varepsilon}{4m}\right) = y\right) \leq \left(1 + \frac{\varepsilon}{4m}\right) \cdot \frac{1}{N_R(x_i)}$$

Por lo tanto:

$$\sum_{y \in \text{Ext}_R(x_i, w_i)} \frac{1}{\left(1 + \frac{\varepsilon}{4m}\right)} \cdot \frac{1}{N_R(x_i)} \leq \mathbf{E}[X_{w_i}] \leq \sum_{y \in \text{Ext}_R(x_i, w_i)} \left(1 + \frac{\varepsilon}{4m}\right) \cdot \frac{1}{N_R(x_i)}$$

De lo cual concluimos que:

$$\frac{1}{\left(1 + \frac{\varepsilon}{4m}\right)} \cdot \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \mathbf{E}[X_{w_i}] \leq \left(1 + \frac{\varepsilon}{4m}\right) \cdot \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)}$$

## Otra desigualdad útil

Para  $\varepsilon \in (0, 1)$ , se tiene que:

$$1 + \frac{\varepsilon}{2m} \geq \left(1 + \frac{\varepsilon}{5m}\right) \cdot \left(1 + \frac{\varepsilon}{4m}\right)$$

Puesto que  $\varepsilon \in (0, 1)$  y:

$$\begin{aligned} 1 + \frac{\varepsilon}{2m} \geq \left(1 + \frac{\varepsilon}{5m}\right) \cdot \left(1 + \frac{\varepsilon}{4m}\right) &\Leftrightarrow 1 + \frac{\varepsilon}{2m} \geq 1 + \frac{\varepsilon}{4m} + \frac{\varepsilon}{5m} + \frac{\varepsilon^2}{20m} \\ &\Leftrightarrow \frac{\varepsilon}{2m} \geq \frac{\varepsilon}{4m} + \frac{\varepsilon}{5m} + \frac{\varepsilon^2}{20m} \\ &\Leftrightarrow 10\varepsilon \geq 5\varepsilon + 4\varepsilon + \varepsilon^2 \\ &\Leftrightarrow \varepsilon \geq \varepsilon^2 \\ &\Leftrightarrow 1 \geq \varepsilon \end{aligned}$$

$$\text{Acotando inferiormente } \Pr\left(\frac{\alpha_i}{(1+\frac{\varepsilon}{2m})} \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq (1 + \frac{\varepsilon}{2m}) \cdot \alpha_i\right)$$

Usando las desigualdades anteriores, tenemos que:

$$\begin{aligned} \frac{1}{(1 + \frac{\varepsilon}{5m})} \cdot \alpha_i \leq \mathbf{E}[X_{w_i}] &\Rightarrow \frac{1}{(1 + \frac{\varepsilon}{5m})} \cdot \alpha_i \leq \left(1 + \frac{\varepsilon}{4m}\right) \cdot \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \\ &\Rightarrow \frac{1}{(1 + \frac{\varepsilon}{5m}) \cdot (1 + \frac{\varepsilon}{4m})} \cdot \alpha_i \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \\ &\Rightarrow \frac{1}{(1 + \frac{\varepsilon}{2m})} \cdot \alpha_i \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \end{aligned}$$

De la misma forma obtenemos:

$$\mathbf{E}[X_{w_i}] \leq \left(1 + \frac{\varepsilon}{5m}\right) \cdot \alpha_i \Rightarrow \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot \alpha_i$$

Acotando inferiormente  $\Pr\left(\frac{\alpha_i}{(1+\frac{\varepsilon}{2m})} \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq (1 + \frac{\varepsilon}{2m}) \cdot \alpha_i\right)$

Juntando todo lo anterior, finalmente concluimos que:

$$\Pr\left(\frac{\alpha_i}{(1 + \frac{\varepsilon}{2m})} \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot \alpha_i\right) \geq$$
$$\Pr\left(\frac{\alpha_i}{(1 + \frac{\varepsilon}{5m})} \leq \mathbf{E}[X_{w_i}] \leq \left(1 + \frac{\varepsilon}{5m}\right) \cdot \alpha_i\right) \geq 1 - \frac{1}{5m}$$

# Acotando inferiormente $\Pr(\text{propiedad de aproximación})$ : el paso final

Recuerde que nuestro objetivo es demostrar que:

$$\Pr(\text{propiedad de aproximación}) \geq \frac{3}{4}$$

Tenemos que:

$$\Pr(\text{propiedad de aproximación}) =$$

$$\begin{aligned} & \Pr\left(\bigwedge_{i=1}^s \left[ \frac{\alpha_i}{\left(1 + \frac{\varepsilon}{2m}\right)} \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot \alpha_i \right]\right) = \\ & \prod_{i=1}^s \Pr\left(\frac{\alpha_i}{\left(1 + \frac{\varepsilon}{2m}\right)} \leq \frac{|\text{Ext}_R(x_i, w_i)|}{N_R(x_i)} \leq \left(1 + \frac{\varepsilon}{2m}\right) \cdot \alpha_i\right) \geq \\ & \prod_{i=1}^s \left(1 - \frac{1}{5m}\right) = \left(1 - \frac{1}{5m}\right)^s \geq \left(1 - \frac{1}{5m}\right)^m \end{aligned}$$

## Acotando inferiormente $\Pr(\text{propiedad de aproximación})$ : el paso final

Dado que  $m \geq 1$  tenemos que  $\left(1 - \frac{1}{5m}\right)^m > \left(e^{-\frac{1}{5}} - \frac{1}{50}\right) > \frac{3}{4}$

Concluimos finalmente que:

$$\Pr(\text{propiedad de aproximación}) \geq \left(1 - \frac{1}{5m}\right)^m \geq \frac{3}{4}$$

Esto termina la demostración del teorema. □