


# Muestreo


- ▶ En el caso de percolación, todas las realizaciones son equiprobables.



Elegimos 27.000 realizaciones sobre un espacio de  $2^N$  posibilidades.

# ¿Qué ocurre si las configuraciones **no** son equiprobables?

- ▶ Ejemplo: la distribución de fragmentos no es uniforme (obvio!)

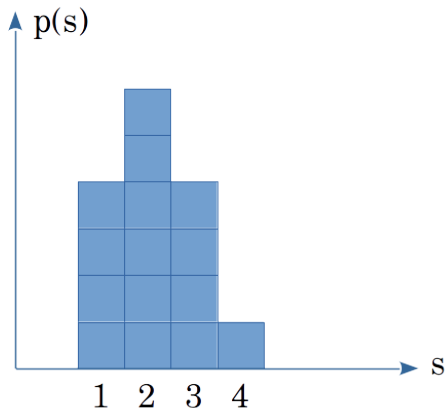


- ▶ Si queremos calcular el tamaño medio de los fragmentos

$$\langle s \rangle = \sum_{s=1}^4 s \cdot n(s) = 1p(1) + 2p(2) + 3p(3) + 4p(4) \quad (1)$$

## ¿Qué ocurre si las configuraciones **no** son equiprobables?


- ▶ Pero entonces me **conviene** generar configuraciones con la siguiente distribución:



- ▶ Favorecemos las configuraciones **más probables**.

## ¿Cómo lo hacemos?

- ▶ Si generamos configuraciones **random**, los tamaños irán apareciendo por ejemplo así:



$$s_i = 1, 3, 2, 3, 1, 2, 4, 2, 3, \dots$$

$$\langle s \rangle = \frac{1 + 3 + 2 + 3 + 1 + 2 + 4 + 2 + 3}{N} \quad (2)$$

⇒ generamos  $4N$  valores (0 o 1), los sumamos y luego promediamos.

## ¿Cómo lo hacemos?

- ▶ Pero si generamos configuraciones con probabilidad  $p(1)$ ,  $p(2)$ ,  $p(3)$ ,  $p(4)$ , los tamaños irán apareciendo por ejemplo así:

$$s_i = 1, 3, 1, 2, 3, 2, 2, 3, 2, 3, 1, 2, 2, 1, 4, \dots$$

⇒ las configuraciones más probables aparecen más frecuentemente.

# ¿Cómo lo hacemos?


Los pasos metodológicos son:

- (1) Estudio qué tipo de distribución tienen las configuraciones.
- (2) Re-balanceo el muestreo según la distribución de configuraciones
- (3) Calculo el observable a partir del muestreo “ponderado”

⇒ el paso (2) es el más complejo porque debe ser “eficiente”.

⇒ usamos un “caminador” para muestrear según el paso (2).


## ¿Cómo lo hacemos?



- ▶ Inicio con  $s_0 = 3$ .
- ▶ Elegimos  $s_1 = 4$  con probabilidad  $1/4$ , sino nos quedamos en  $s_1 = 3$ .
- ▶ Elegimos  $s_2 = 2$  con probabilidad  $3/2$  (¡!).

## ¿Esto funciona siempre?

- ▶ No siempre!!!



⇒ Si no elegimos bien el tamaño del “salto” podemos estar “rebotando” entre dos valores únicamente!



## Aplicación al problema 1 (guía 2)

Se pide calcular la siguiente integral:

$$I = \int_{-\infty}^{\infty} dx x^2 e^{-x^2/2} \quad (3)$$

- (1) Estudio qué tipo de distribución tienen las configuraciones.

La integral corresponde a la definición de  $\langle x^2 \rangle$ . Entonces el espacio configuracional (1D) tiene distribución:

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \quad (4)$$

- (2) Re-balanceo el muestreo según la distribución de configuraciones

Voy a tener que generar valores  $x_0, x_1, x_3, \dots, x_i, \dots$  siguiendo una distribución normal.

## Aplicación al problema 1 (guía 2)

(3) Calculo el observable a partir del muestreo “ponderado”

$$I = \sqrt{2\pi} \sum_{i=0}^N \frac{x_i^2}{N} \quad (5)$$

Observar que lo difícil es generar los  $x_i$  siguiendo la distribución “deseada”.


Vamos a usar el siguiente “caminador”:

$$\frac{f(x_{i+1})}{f(x_i)} = \frac{e^{-x_{i+1}^2}}{e^{-x_i^2}} = e^{-(x_{i+1}^2 - x_i^2)/2} \quad (6)$$

para un tamaño de “paso”  $\text{rand}(-\delta, \delta)$ .


## Aplicación al problema 1 (guía 2)

$\delta = 1.0$  (uncorrelated)




## Aplicación al problema 1 (guía 2)

$\delta = 0.1$  (uncorrelated)




## Aplicación al problema 1 (guía 2)

Correlation




## Aplicación al problema 1 (guía 2)

$\delta = 1.0$  ( $N = 10000$  uncorrelated)



## Aplicación al problema 1 (guía 2)

$\delta = 0.1$  ( $N = 10000$  correlated)



## Aplicación al problema 1 (guía 2)

```
for(i=0;i<N;i++)  
{  
    p = myrand();  
    x = trial(x0);  
    w = exp(-0.5*(x*x-x0*x0));  
  
    if (p<w) x0 = x;  
  
    if (i%100==0) printf("%lf\n",x0);  
}
```



## Aplicación al problema 1 (guía 2)

```
double myrand()  
{  
    double p;  
    p = (double)rand()/(double)RAND_MAX;  
  
    return p;  
}
```

```
double trial(double x0)  
{  
    double p,x;  
  
    p = myrand();  
  
    x = 2.0*DELTA*(p-0.5)+x0;
```