

Estimación insesgada, asignación de bolas en urnas y árboles aleatorios

Fernando López-Blázquez

Sanlúcar de Barrameda, Cádiz
28–30 Noviembre 2014

Índice

- 1 Estimación insesgada
- 2 Modelos de asignación aleatoria de bolas en urnas
- 3 Árboles aleatorios

Modelo básico

- $X_1, \dots, X_N \stackrel{iid}{\sim} F(x; \theta)$
- Objetivo: **Estimación puntual**
Encontrar una función de la muestra (datos) que *aproxime razonablemente* a $H(\theta)$, i.e.,

$$T_N(X_1, \dots, X_N) \approx H(\theta)$$

Modelo básico

- $X_1, \dots, X_N \stackrel{iid}{\sim} F(x; \theta)$
- Objetivo: **Estimación puntual**

Encontrar una función de la muestra (datos) que *aproxime razonablemente* a $H(\theta)$, i.e.,

$$T_N(X_1, \dots, X_N) \approx H(\theta)$$

Modelo básico

- $X_1, \dots, X_N \stackrel{iid}{\sim} F(x; \theta)$
- Objetivo: **Estimación puntual**
Encontrar una función de la muestra (datos) que *aproxime razonablemente* a $H(\theta)$, i.e.,

$$T_N(X_1, \dots, X_N) \approx H(\theta)$$

Estimación incesgada

Dado $H(\theta)$ encontrar $T_N = T_N(X_1, \dots, X_N)$ tal que:

$$\mathbb{E}_\theta T_N = H(\theta), \quad \forall \theta$$

Teoría B-R-L-S

- Un estadístico $S_N = S_N(X_1, \dots, X_N)$ es **suficiente** si

$$(X_1, \dots, X_N) \mid S_N \text{ no depende de } \theta$$

- Un estadístico $S_N = S_N(X_1, \dots, X_N)$ es **completo**

$$\mathbb{E}_\theta g(S_N) = 0, \forall \theta \Rightarrow g = 0, \mathbb{P}_\theta - \text{c.s.}$$

Teoría B-R-L-S

- Si la familia de distribuciones $F(\cdot, \theta)$ admite un estadístico suficiente y completo, los estimadores insesgados de una función paramétrica $H(\theta)$ deben ser obtenidos, si fuera posible, como funciones del estadístico suficiente y completo:

$$\mathbb{E}_\theta T_N(S_N) = H(\theta), \forall \theta$$

Ejemplo

- Sea $X_1, \dots, X_N \stackrel{iid}{\sim} \text{Po}(\theta)$ deseamos estimar $H(\theta) = \mathbb{P}_\theta(X = 0) = e^{-\theta}$.
- Un estadístico suficiente y completo es

$$S_N = \sum_{i=1}^N X_i \sim \text{Po}(N\theta)$$

- El estimador insesgado se obtiene resolviendo

$$E_\theta T_N(S_N) = e^{-\theta}$$

Ejemplo

- Sea $X_1, \dots, X_N \stackrel{iid}{\sim} \text{Po}(\theta)$ deseamos estimar $H(\theta) = \mathbb{P}_\theta(X = 0) = e^{-\theta}$.
- Un estadístico suficiente y completo es

$$S_N = \sum_{i=1}^N X_i \sim \text{Po}(N\theta)$$

- El estimador insesgado se obtiene resolviendo

$$E_\theta T_N(S_N) = e^{-\theta}$$

Ejemplo

- Sea $X_1, \dots, X_N \stackrel{iid}{\sim} \text{Po}(\theta)$ deseamos estimar $H(\theta) = \mathbb{P}_\theta(X = 0) = e^{-\theta}$.
- Un estadístico suficiente y completo es

$$S_N = \sum_{i=1}^N X_i \sim \text{Po}(N\theta)$$

- El estimador insesgado se obtiene resolviendo

$$E_\theta T_N(S_N) = e^{-\theta}$$

Ejemplo - Continuación

- Es decir:

$$\sum_{n=0}^{\infty} T_N(n) e^{-N\theta} \frac{(N\theta)^n}{n!} = e^{-\theta}$$

- luego

$$T_N(n) = \left(1 - \frac{1}{N}\right)^n$$

- y es estimador buscado es

$$T_N = \left(1 - \frac{1}{N}\right)^{\sum_{i=1}^N X_i}$$

Ejemplo - Continuación

- Es decir:

$$\sum_{n=0}^{\infty} T_N(n) e^{-N\theta} \frac{(N\theta)^n}{n!} = e^{-\theta}$$

- luego

$$T_N(n) = \left(1 - \frac{1}{N}\right)^n$$

- y es estimador buscado es

$$T_N = \left(1 - \frac{1}{N}\right)^{\sum_{i=1}^N X_i}$$

Ejemplo - Continuación

- Es decir:

$$\sum_{n=0}^{\infty} T_N(n) e^{-N\theta} \frac{(N\theta)^n}{n!} = e^{-\theta}$$

- luego

$$T_N(n) = \left(1 - \frac{1}{N}\right)^n$$

- y es estimador buscado es

$$T_N = \left(1 - \frac{1}{N}\right)^{\sum_{i=1}^N X_i}$$

Distribuciones de series de potencias (PSD)

Definición

Sea $G(\theta) = \sum_{k \geq 0} g_k \theta^k$ con $g_k \geq 0$, $\forall k \geq 0$. Entonces,

$$X \sim PSD(G(\theta)) \Leftrightarrow \mathbb{P}_\theta(X = k) = \frac{g_k \theta^k}{G(\theta)}, \quad k \geq 0$$

Ejemplos

$$\begin{aligned} X \sim Po(\theta) &\Leftrightarrow X \sim PSD(e^\theta) \\ X \sim Ge(\theta) &\Leftrightarrow X \sim PSD((1 - \theta)^{-1}) \\ X \sim BN(r, \theta) &\Leftrightarrow X \sim PSD((1 - \theta)^{-r}) \\ X \sim Bi(N, \theta) &\Leftrightarrow X \sim PSD((1 + \theta)^N) \end{aligned}$$

Distribuciones de series de potencias (PSD)

Definición

Sea $G(\theta) = \sum_{k \geq 0} g_k \theta^k$ con $g_k \geq 0$, $\forall k \geq 0$. Entonces,

$$X \sim PSD(G(\theta)) \Leftrightarrow \mathbb{P}_\theta(X = k) = \frac{g_k \theta^k}{G(\theta)}, \quad k \geq 0$$

Ejemplos

$$\begin{aligned} X \sim Po(\theta) &\Leftrightarrow X \sim PSD(e^\theta) \\ X \sim Ge(\theta) &\Leftrightarrow X \sim PSD((1 - \theta)^{-1}) \\ X \sim BN(r, \theta) &\Leftrightarrow X \sim PSD((1 - \theta)^{-r}) \\ X \sim Bi(N, \theta) &\Leftrightarrow X \sim PSD((1 + \theta)^N) \end{aligned}$$

Estimación incesgada en PSD



$$\left. \begin{array}{l} X_j \stackrel{iid}{\sim} PSD(G(\theta)) \\ \text{independientes, } j = 1, \dots, N \end{array} \right\} \Rightarrow S_N = \sum_{j=1}^N X_j \sim PSD(G^N(\theta))$$

es decir:

$$\mathbb{P}_\theta(S_N = n) = \frac{g_{N,n}\theta^n}{G^N(\theta)}, \quad n \geq 0, \theta \geq 0$$

- S_N es suficiente y completo

Estimación incesgada en PSD

- Si buscamos un estimador incesgado, T_N de $H(\theta)$ debemos resolver:

$$\sum_{n \geq 0} T_N(n) \frac{g_{N,n} \theta^n}{G^N(\theta)} = H(\theta), \quad \forall \theta$$

La transformación PSD

- La relación anterior puede entenderse como un funcional:

$$T_N \circ \text{---} \bullet H$$

que denominaremos **transformación PSD**

- *Obtener un estimador incesgado consiste básicamente en invertir la transformación PSD.*

La transformaci3n PSD

- La relaci3n anterior puede entenderse como un funcional:

$$T_N \circ \text{---} \bullet H$$

que denominaremos **transformaci3n PSD**

- *Obtener un estimador incesgado consiste b3sicamente en invertir la transformaci3n PSD.*

Asignación aleatoria

- Sean N urnas distinguibles (numeradas)
- Se colocarán n bolas en las urnas.
- El conjunto de todas las posibles asignaciones es:

$$\Omega_{n,N} = \left\{ \omega = (y_1, \dots, y_N) \in \mathbb{N}_0^N : \sum_{i=1}^N y_i = n \right\}$$

Asignación aleatoria

- Sean N urnas distinguibles (numeradas)
- Se colocarán n bolas en las urnas.
- El conjunto de todas las posibles asignaciones es:

$$\Omega_{n,N} = \left\{ \omega = (y_1, \dots, y_N) \in \mathbb{N}_0^N : \sum_{i=1}^n y_i = n \right\}$$

Asignación aleatoria

- Sea $\{w_k\}_{k \geq 0}$ una sucesión de números reales no negativos.
- Para cada asignación $\omega = (y_1, \dots, y_N)$ se define su peso:

$$\mathbf{w}(\omega) := \prod_{j=1}^N w_{y_j}$$

Asignación aleatoria

- El modelo de asignación aleatoria consiste en seleccionar una asignación en $\Omega_{n,N}$ con **probabilidad proporcional al peso**:

$$\mathbb{P}(Y_1 = y_1, \dots, Y_N = y_N) \propto \mathbf{w}(\omega)$$

- es decir:

$$\mathbb{P}(Y_1 = y_1, \dots, Y_N = y_N) = \frac{\prod_{j=1}^N w_{y_j}}{Z(N, n)}$$

donde $Z(N, n) = \sum_{\mathbf{y} \in \Omega_{n,N}} \prod_{j=1}^N w_{y_j}$ (función de partición)

Resultado fundamental

- Sea (Y_1, \dots, Y_N) es una asignación aleatoria en $\Omega_{n,N}$ (N urnas y n bolas) con pesos asociados $\{w_k\}_{k \geq 0}$.
- Sean $X_1, \dots, X_N \stackrel{\text{iid}}{\sim} PSD(G(\theta))$ con $G(\theta) = \sum_k w_k \theta^k$ y $S_N = X_1 + \dots + X_N$

Teorema

$$(Y_1, \dots, Y_N) \stackrel{d}{=} (X_1, \dots, X_N) \mid S_N = n$$

Resultado fundamental

- Sea (Y_1, \dots, Y_N) es una asignación aleatoria en $\Omega_{n,N}$ (N urnas y n bolas) con pesos asociados $\{w_k\}_{k \geq 0}$.
- Sean $X_1, \dots, X_N \stackrel{\text{iid}}{\sim} PSD(G(\theta))$ con $G(\theta) = \sum_k w_k \theta^k$ y $S_N = X_1 + \dots + X_N$

Teorema

$$(Y_1, \dots, Y_N) \stackrel{d}{=} (X_1, \dots, X_N) \mid S_N = n$$

Cantidades de interés en modelos de urnas

La mayoría son de la forma:

$$E(g(Y_1, \dots, Y_N)), \quad g \text{ medible}$$

- **Ejemplos**

- Función de probabilidad conjunta:

$$P(Y_1 = y_1, \dots, Y_N = y_N) = E(I(Y_1 = y_1, \dots, Y_N = y_N))$$

- Probabilidades marginales: $P(Y_j = y_j) = E(I(Y_j = y_j))$
- Momentos: EY_j^k
- Distribución de Multiplicidades

$$\mathbb{P}\left(\sum_i \mathbf{1}\{Y_i = r\} = j\right)$$

- Gaps, colisiones, maximas ocupaciones... etc

Cantidades de interés en modelos de urnas

La mayoría son de la forma:

$$E(g(Y_1, \dots, Y_N)), \quad g \text{ medible}$$

● Ejemplos

- Función de probabilidad conjunta:

$$P(Y_1 = y_1, \dots, Y_N = y_N) = E(I(Y_1 = y_1, \dots, Y_N = y_N))$$

- Probabilidades marginales: $P(Y_j = y_j) = E(I(Y_j = y_j))$
- Momentos: EY_j^k
- Distribución de Multiplicidades

$$\mathbb{P}\left(\sum_i \mathbf{1}\{Y_i = r\} = j\right)$$

- Gaps, colisiones, máximas ocupaciones... etc

Cantidades de interés en modelos de urnas

La mayoría son de la forma:

$$E(g(Y_1, \dots, Y_N)), \text{ } g \text{ medible}$$

● Ejemplos

- Función de probabilidad conjunta:

$$P(Y_1 = y_1, \dots, Y_N = y_N) = E(I(Y_1 = y_1, \dots, Y_N = y_N))$$

- Probabilidades marginales: $P(Y_j = y_j) = E(I(Y_j = y_j))$
- Momentos: EY_j^k
- Distribución de Multiplicidades

$$\mathbb{P}\left(\sum_i \mathbf{1}\{Y_i = r\} = j\right)$$

- Gaps, colisiones, maximas ocupaciones... etc

Cantidades de interés en modelos de urnas

La mayoría son de la forma:

$$E(g(Y_1, \dots, Y_N)), \text{ } g \text{ medible}$$

● Ejemplos

- Función de probabilidad conjunta:

$$P(Y_1 = y_1, \dots, Y_N = y_N) = E(I(Y_1 = y_1, \dots, Y_N = y_N))$$

- Probabilidades marginales: $P(Y_j = y_j) = E(I(Y_j = y_j))$
- Momentos: EY_j^k
- Distribución de Multiplicidades

$$\mathbb{P}\left(\sum_i \mathbf{1}\{Y_i = r\} = j\right)$$

- Gaps, colisiones, maximas ocupaciones... etc

Cantidades de interés en modelos de urnas

La mayoría son de la forma:

$$E(g(Y_1, \dots, Y_N)), \text{ } g \text{ medible}$$

● Ejemplos

- Función de probabilidad conjunta:

$$P(Y_1 = y_1, \dots, Y_N = y_N) = E(I(Y_1 = y_1, \dots, Y_N = y_N))$$

- Probabilidades marginales: $P(Y_j = y_j) = E(I(Y_j = y_j))$
- Momentos: EY_j^k
- Distribución de Multiplicidades

$$\mathbb{P}\left(\sum_i \mathbf{1}\{Y_i = r\} = j\right)$$

- Gaps, colisiones, maximas ocupaciones... etc

Cantidades de interés en modelos de urnas

La mayoría son de la forma:

$$E(g(Y_1, \dots, Y_N)), \quad g \text{ medible}$$

● Ejemplos

- Función de probabilidad conjunta:

$$P(Y_1 = y_1, \dots, Y_N = y_N) = E(I(Y_1 = y_1, \dots, Y_N = y_N))$$

- Probabilidades marginales: $P(Y_j = y_j) = E(I(Y_j = y_j))$
- Momentos: EY_j^k
- Distribución de Multiplicidades

$$\mathbb{P}\left(\sum_i \mathbf{1}\{Y_i = r\} = j\right)$$

- Gaps, colisiones, maximas ocupaciones,...etc

Transformaciones en modelos de urnas

Se verifica que $E_\theta(g(X_1, \dots, X_N))$ es la $PSD(G^N(\theta))$ -transformada de $E(g(Y_1, \dots, Y_N))$, es decir

$$E(g(Y_1, \dots, Y_N)) \circ \text{---} \bullet E_\theta(g(X_1, \dots, X_N))$$

Maxwell-Boltzmann

- n bolas numeradas en N urnas distinguibles
- Sucesión de pesos: $w_k = \frac{1}{k!}$
- Función de probabilidad conjunta de las asignaciones

$$P(Y_1 = y_1, \dots, Y_N = y_N) = \frac{n!}{\prod_j y_j!} \frac{1}{N^n}$$

para $y_1 + \dots + y_N = n$

- PSD asociada: $X_j \stackrel{iid}{\sim} PSD(\exp(\theta)) \equiv Po(\theta)$
- $S_N = \sum_{j=1}^N X_j(\theta) \sim Po(N\theta)$
- La transformación asociada es

$$H(\theta) = \sum_{n=0}^{\infty} T_N(n) \exp(-N\theta) \frac{(N\theta)^n}{n!}$$

Poissonización

Maxwell-Boltzmann

- n bolas numeradas en N urnas distinguibles
- Sucesión de pesos: $w_k = \frac{1}{k!}$
- Función de probabilidad conjunta de las asignaciones

$$P(Y_1 = y_1, \dots, Y_N = y_N) = \frac{n!}{\prod_j y_j!} \frac{1}{N^n}$$

para $y_1 + \dots + y_N = n$

- PSD asociada: $X_j \stackrel{iid}{\sim} PSD(\exp(\theta)) \equiv Po(\theta)$
- $S_N = \sum_{j=1}^N X_j(\theta) \sim Po(N\theta)$
- La transformación asociada es

$$H(\theta) = \sum_{n=0}^{\infty} T_N(n) \exp(-N\theta) \frac{(N\theta)^n}{n!}$$

Poissonización

Maxwell-Boltzmann

- n bolas numeradas en N urnas distinguibles
- Sucesión de pesos: $w_k = \frac{1}{k!}$
- Función de probabilidad conjunta de las asignaciones

$$P(Y_1 = y_1, \dots, Y_N = y_N) = \frac{n!}{\prod_j y_j!} \frac{1}{N^n}$$

para $y_1 + \dots + y_N = n$

- PSD asociada: $X_j \stackrel{iid}{\sim} PSD(\exp(\theta)) \equiv Po(\theta)$
- $S_N = \sum_{j=1}^N X_j(\theta) \sim Po(N\theta)$
- La transformación asociada es

$$H(\theta) = \sum_{n=0}^{\infty} T_N(n) \exp(-N\theta) \frac{(N\theta)^n}{n!}$$

Poissonización

Maxwell-Boltzmann

- n bolas numeradas en N urnas distinguibles
- Sucesión de pesos: $w_k = \frac{1}{k!}$
- Función de probabilidad conjunta de las asignaciones

$$P(Y_1 = y_1, \dots, Y_N = y_N) = \frac{n!}{\prod_j y_j!} \frac{1}{N^n}$$

para $y_1 + \dots + y_N = n$

- PSD asociada: $X_j \stackrel{iid}{\sim} PSD(\exp(\theta)) \equiv Po(\theta)$
- $S_N = \sum_{j=1}^N X_j(\theta) \sim Po(N\theta)$
- La transformación asociada es

$$H(\theta) = \sum_{n=0}^{\infty} T_N(n) \exp(-N\theta) \frac{(N\theta)^n}{n!}$$

Poissonización

Maxwell-Boltzmann

- n bolas numeradas en N urnas distinguibles
- Sucesión de pesos: $w_k = \frac{1}{k!}$
- Función de probabilidad conjunta de las asignaciones

$$P(Y_1 = y_1, \dots, Y_N = y_N) = \frac{n!}{\prod_j y_j!} \frac{1}{N^n}$$

para $y_1 + \dots + y_N = n$

- PSD asociada: $X_j \stackrel{iid}{\sim} PSD(\exp(\theta)) \equiv Po(\theta)$
- $S_N = \sum_{j=1}^N X_j(\theta) \sim Po(N\theta)$
- La transformación asociada es

$$H(\theta) = \sum_{n=0}^{\infty} T_N(n) \exp(-N\theta) \frac{(N\theta)^n}{n!}$$

Poissonización

Maxwell-Boltzmann

- n bolas numeradas en N urnas distinguibles
- Sucesión de pesos: $w_k = \frac{1}{k!}$
- Función de probabilidad conjunta de las asignaciones

$$P(Y_1 = y_1, \dots, Y_N = y_N) = \frac{n!}{\prod_j y_j!} \frac{1}{N^n}$$

para $y_1 + \dots + y_N = n$

- PSD asociada: $X_j \stackrel{iid}{\sim} PSD(\exp(\theta)) \equiv Po(\theta)$
- $S_N = \sum_{j=1}^N X_j(\theta) \sim Po(N\theta)$
- La transformación asociada es

$$H(\theta) = \sum_{n=0}^{\infty} T_N(n) \exp(-N\theta) \frac{(N\theta)^n}{n!}$$

Poissonización

Ejercicio...

Calcular la probabilidad de que haya k urnas vacías

Solución

- El número de urnas vacías es

$$M_0 := \sum_{i=1}^N \mathbf{1}\{Y_i = 0\}$$

- Se tiene:

$$\mathbb{P}\left(\sum_{i=1}^N \mathbf{1}\{Y_i = 0\} = k\right) \circ \text{---} \bullet \mathbb{P}\left(\sum_{i=1}^N \mathbf{1}\{X_i = 0\} = k\right)$$

- Pero $\sum_{i=1}^N \mathbf{1}\{X_i = 0\} \sim \text{Bi}(N, e^{-\theta})$

Solución

- El número de urnas vacías es

$$M_0 := \sum_{i=1}^N \mathbf{1}\{Y_i = 0\}$$

- Se tiene:

$$\mathbb{P}\left(\sum_{i=1}^N \mathbf{1}\{Y_i = 0\} = k\right) \circ \text{---} \bullet \mathbb{P}\left(\sum_{i=1}^N \mathbf{1}\{X_i = 0\} = k\right)$$

- Pero $\sum_{i=1}^N \mathbf{1}\{X_i = 0\} \sim \text{Bi}(N, e^{-\theta})$

Solución

- El número de urnas vacías es

$$M_0 := \sum_{i=1}^N \mathbf{1}\{Y_i = 0\}$$

- Se tiene:

$$\mathbb{P}\left(\sum_{i=1}^N \mathbf{1}\{Y_i = 0\} = k\right) \circ \text{---} \bullet \mathbb{P}\left(\sum_{i=1}^N \mathbf{1}\{X_i = 0\} = k\right)$$

- Pero $\sum_{i=1}^N \mathbf{1}\{X_i = 0\} \sim \text{Bi}(N, e^{-\theta})$

Solución

- Entonces:

$$\begin{aligned}
 & \mathbb{P} \left(\sum_{i=1}^N \mathbf{1}\{Y_i = 0\} = k \right) \circ \text{---} \bullet \mathbb{P} \left(\sum_{i=1}^N \mathbf{1}\{X_i = 0\} = k \right) = \\
 & = \binom{N}{k} e^{-k\theta} (1 - e^{-\theta})^{N-k} \bullet \text{---} \circ \\
 & \binom{N}{k} \sum_{j=0}^{N-k-1} \binom{N-k}{j} (-1)^j \left(1 - \frac{k+j}{N} \right)^n
 \end{aligned}$$

Ejercicio....

¿Cuál es el valor esperado del número de urnas vacías?

Solución

- Sean

$$M_0 := \sum_{i=1}^N \mathbf{1}\{Y_i = 0\}$$

$$M_0^* := \sum_{i=1}^N \mathbf{1}\{X_i = 0\} \sim \text{Bi}(N, e^{-\theta})$$

- Entonces:

$$\mathbb{E}M_0 \text{ --- } \bullet \mathbb{E}M_0^* = Ne^{-\theta} \text{ --- } \circ \left(1 - \frac{1}{N}\right)^n$$

Solución

- Sean

$$M_0 := \sum_{i=1}^N \mathbf{1}\{Y_i = 0\}$$

$$M_0^* := \sum_{i=1}^N \mathbf{1}\{X_i = 0\} \sim \text{Bi}(N, e^{-\theta})$$

- Entonces:

$$\mathbb{E}M_0 = \mathbb{E}M_0^* = Ne^{-\theta} = \left(1 - \frac{1}{N}\right)^n$$

Árboles aleatorios finitamente generados

- Consideremos el conjunto de árboles con n nodos, \mathfrak{T}_n .
- Sea $d^+(v)$ el número de nodos que cuelgan del vértice v (outdegree)
- Sea la sucesión de pesos (no negativos) $\{w_k\}_{k \geq 0}$
- El peso asociado a un árbol $T \in \mathfrak{T}_n$ es

$$w(T) := \prod_{v \in T} w_{d^+(v)}$$

Árboles aleatorios finitamente generados

- Seleccionar un árbol en \mathfrak{T}_n con probabilidad proporcional al peso:

$$\mathbb{P}(\mathcal{T} = T) \propto \prod_{v \in T} w_{d^+(v)}, \quad T \in \mathfrak{T}_n.$$

- es decir:

$$\mathbb{P}(\mathcal{T} = T) = \frac{\prod_{v \in T} w_{d^+(v)}}{Z_n}, \quad T \in \mathfrak{T}_n,$$

donde

$$Z_n = \sum_{T \in \mathfrak{T}_n} \prod_{v \in T} w_{d^+(v)}$$

Árboles aleatorios finitamente generados

- Seleccionar un árbol en \mathfrak{T}_n con probabilidad proporcional al peso:

$$\mathbb{P}(\mathcal{T} = T) \propto \prod_{v \in T} w_{d^+(v)}, \quad T \in \mathfrak{T}_n.$$

- es decir:

$$\mathbb{P}(\mathcal{T} = T) = \frac{\prod_{v \in T} w_{d^+(v)}}{Z_n}, \quad T \in \mathfrak{T}_n,$$

donde

$$Z_n = \sum_{T \in \mathfrak{T}_n} \prod_{v \in T} w_{d^+(v)}$$

Relación entre árboles aleatorios y modelos de asignación


- Un árbol puede asociarse a un modelo de asignación:
Nodo \longrightarrow Urna
Outdegree \longrightarrow Bolas

Relación entre árboles aleatorios y modelos de alocaón

- Un árbol puede asociarse a un modelo de alocaón:
Nodo \longrightarrow Urna
Outdegree \longrightarrow Bolas


Relación entre árboles aleatorios y modelos de asignación

- Consideramos orden **depth-first** en los árboles
- Construimos un modelo de asignación con n urnas (vértices) y $n - 1$ bolas (outdegree)



Relación entre árboles aleatorios y modelos de asignación


- **Desafortunadamente** la relación entre árboles en \mathfrak{T}_n y asignaciones en $\Omega_{n-1,n}$ **no es biyectiva**
- Por ejemplo la asignación $(2, 0, 0, 1, 2, 0) \in \Omega_{n-1,n}$



no se corresponde con ningún árbol en \mathfrak{T}_6 .

Relación entre árboles aleatorios y modelos de asignación

- **Desafortunadamente** la relación entre árboles en \mathfrak{T}_n y asignaciones en $\Omega_{n-1,n}$ **no es biyectiva**
- Por ejemplo la asignación $(2, 0, 0, 1, 2, 0) \in \Omega_{n-1,n}$



no se corresponde con ningún árbol en \mathfrak{T}_6 .


Relación entre árboles aleatorios y modelos de asignación

- Sin embargo una y solo una permutación circular de una asignación en $\Omega_{n-1,n}$ se corresponde con un árbol en \mathfrak{T}_n .

Relación entre árboles aleatorios y modelos de asignación

- En la asignación anterior


$(2, 0, 0, 1, 2, 0)$	NO
$(0, 2, 0, 0, 1, 2)$	NO
$(2, 0, 2, 0, 0, 1)$	NO
$(1, 2, 0, 2, 0, 0)$	SI
$(0, 1, 2, 0, 2, 0)$	NO
$(0, 0, 1, 2, 0, 2)$	NO



Relación entre árboles aleatorios y modelos de asignación

- En la asignación anterior

$(2, 0, 0, 1, 2, 0)$	NO
$(0, 2, 0, 0, 1, 2)$	NO
$(2, 0, 2, 0, 0, 1)$	NO
$(1, 2, 0, 2, 0, 0)$	SI
$(0, 1, 2, 0, 2, 0)$	NO
$(0, 0, 1, 2, 0, 2)$	NO



Conclusión

La estimación incesgada en *PSD*, el estudio de las distribuciones asociadas a modelos de alocaón aleatoria de bolas en urnas y las distribuciones de árboles aleatorios finitamente generados son problemas distintos que pueden ser abordados con una herramienta común:

la transformada *PSD*!