

Mixturas de Exponenciales Truncadas para modelizar distribuciones continuas



Departamento de Estadística y Matemática Aplicada

Universidad de Almería

Índice

- **Aprendizaje:**
 - *Estimadores kernel.*
 - *Aprendizaje estructural.*

Índice

- **Aprendizaje:**
 - *Estimadores kernel.*
 - *Aprendizaje estructural.*
- **Inferencia:**
 - *Propagación Penniless.*


Índice

- **Aprendizaje:**
 - *Estimadores kernel.*
 - *Aprendizaje estructural.*
- **Inferencia:**
 - *Propagación Penniless.*
- **En curso.**

Estimadores kernel

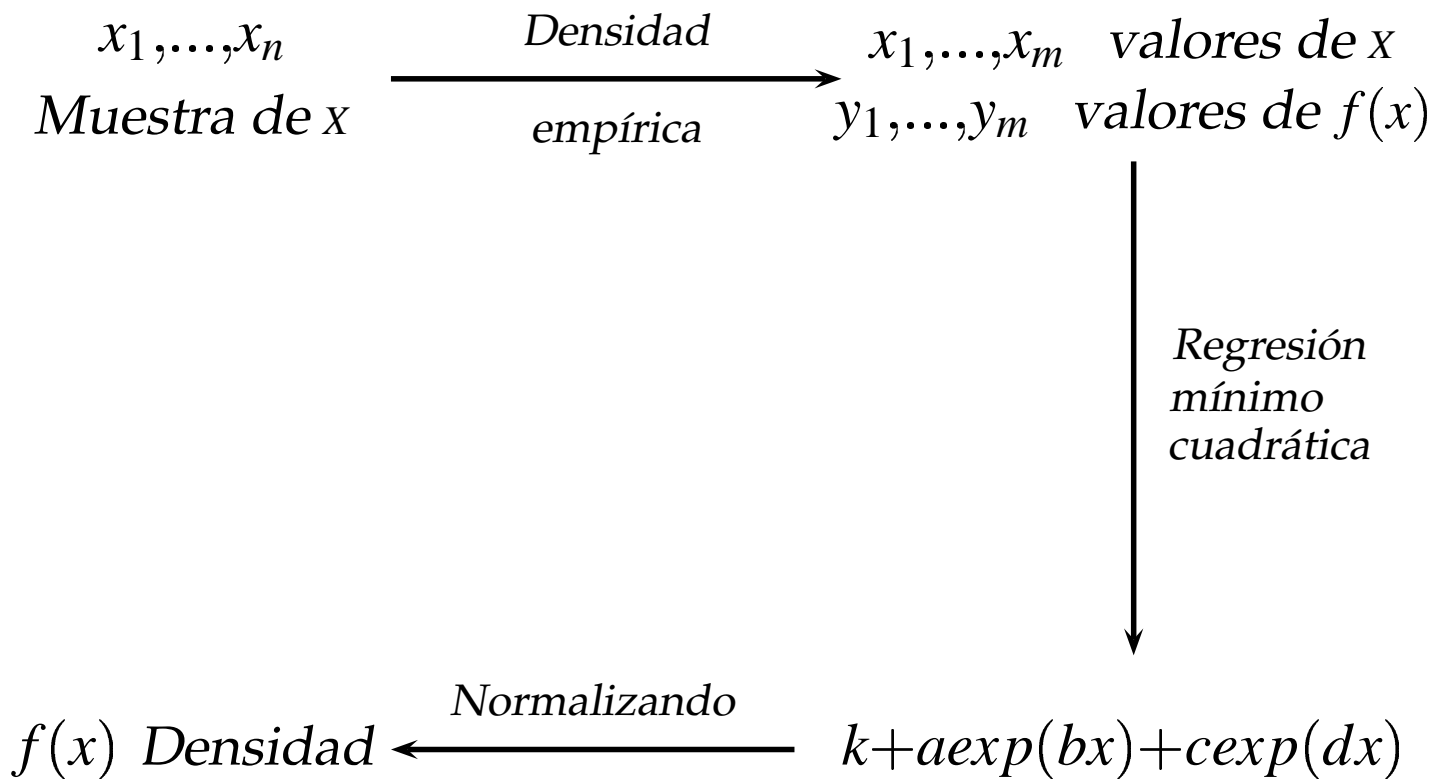
Introducción

Estimación de densidad univariante MTE









Introducción

Estimación de densidad univariante MTE




Introducción




Introducción



Histogram of a



Histogram of b




Histogram of c





Histogram of a



Histogram of b



Histogram of c



Forma del histograma

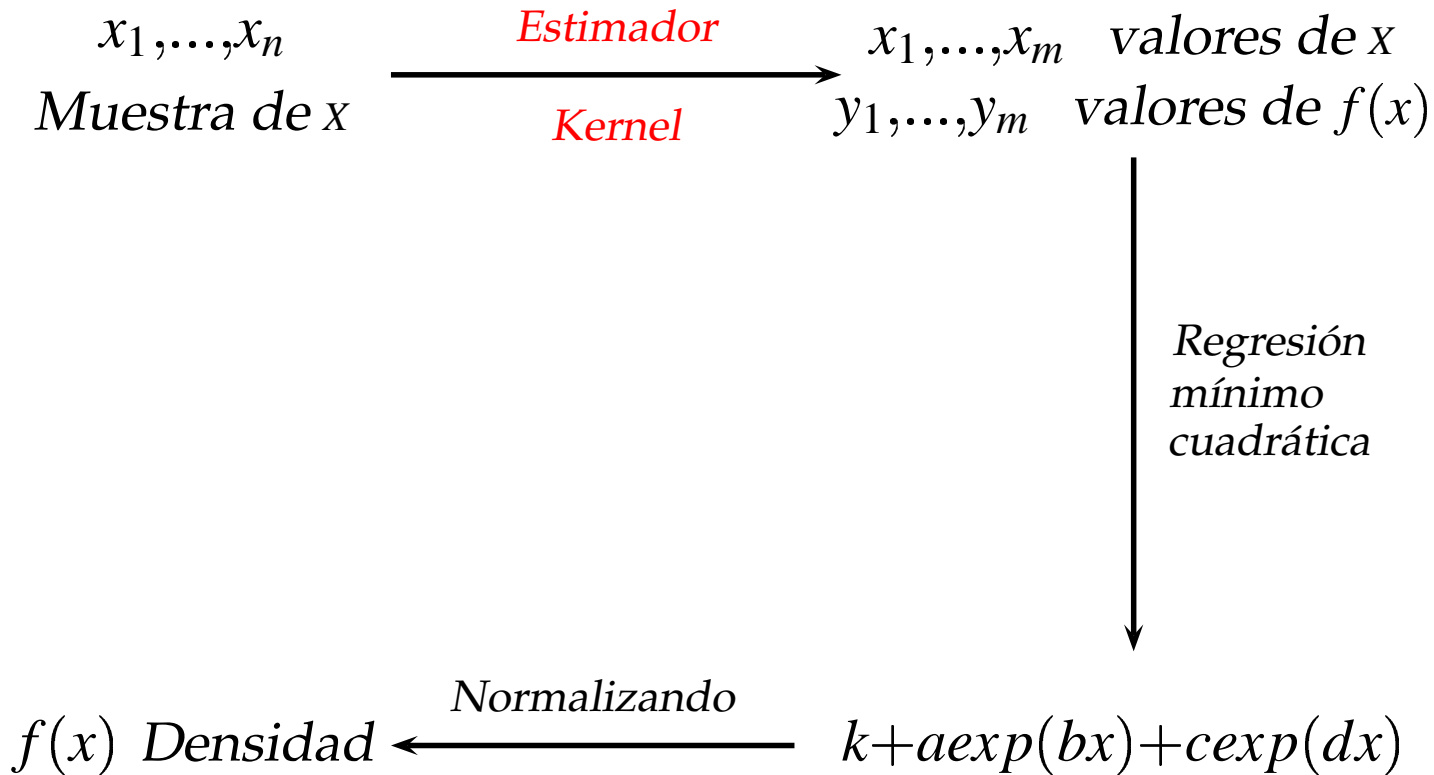
- *Número de intervalos:*
 - *Pocos: Mala regresión / densidad suave.*
 - *Muchos: Mejor regresión / densidad brusca.*

Forma del histograma

- *Número de intervalos:*
 - *Pocos: Mala regresión / densidad suave.*
 - *Muchos: Mejor regresión / densidad brusca.*
- *Selección de los intervalos*
 - *Igual amplitud.*
 - **Igual frecuencia.**

Kernel

Estimación de densidad univariante MTE



Kernel

$\hat{f}(x)$ es una **densidad kernel** :

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

con K una **función kernel** *Propiedades de K* :

- $\int K(u)du = 1$
- $\int uK(u)du = 0$
- $\int u^2K(u)du = \sigma_K^2$

Datos \leftrightarrow $h \leftrightarrow \hat{f}$ kernel (suavizar)


Kernels

<i>Kernel</i>	<i>Form</i>
<i>Epanechnikov</i>	$\frac{3}{4}(1 - u^2)$
<i>Biweight</i>	$\frac{15}{16}(1 - u^2)^2$
<i>Triweight</i>	$\frac{35}{32}(1 - u^2)^3$
<i>Gaussian</i>	$(2\pi)^{-1/2}e^{-u^2/2}$
<i>Uniform</i>	$\frac{1}{2}$

Ejemplo

Muestra: 1.5, 1.7, 2.0, 2.3 $h = 0.3$


$$K(u) = \frac{3}{4}(1 - u^2) \quad |u| \leq 1$$



Ejemplo

Muestra: 1.5, 1.7, 2.0, 2.3 $h = 0.3$


$$K(u) = \frac{3}{4}(1 - u^2) \quad |u| \leq 1$$



Ejemplo

Muestra: 1.5, 1.7, 2.0, 2.3 $h = 0.3$

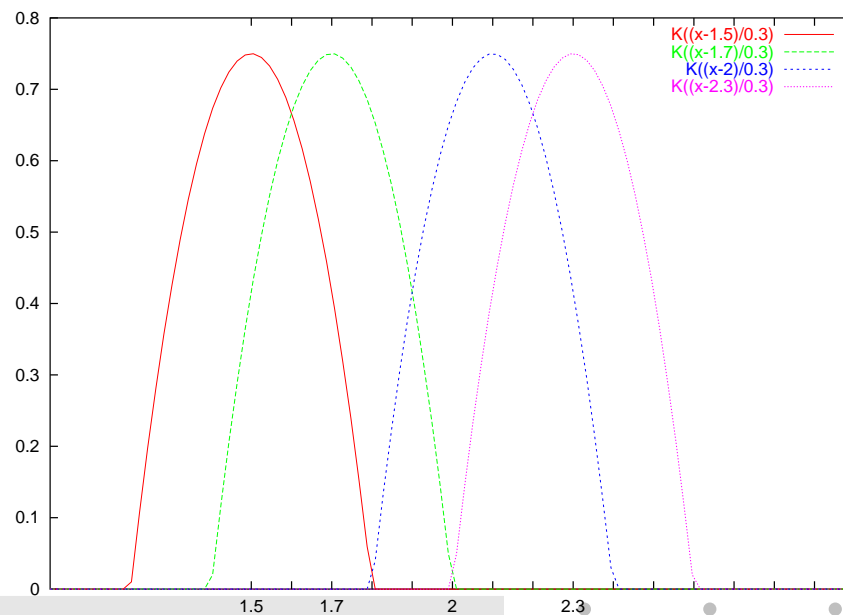
$$K(u) = \frac{3}{4}(1 - u^2) \quad |u| \leq 1$$



Ejemplo

Muestra: 1.5, 1.7, 2.0, 2.3 $h = 0.3$


$$K(u) = \frac{3}{4}(1 - u^2) \quad |u| \leq 1$$



Ejemplo


Muestra: 1.5, 1.7, 2.0, 2.3 $h = 0.3$

$$K(u) = \frac{3}{4}(1 - u^2) \quad |u| \leq 1$$




Ejemplo

$$h = 0.1$$




Ejemplo

$$h = 0.3$$




Ejemplo

$$h = 0.8$$



Ejemplo

$$h = 3$$



Error

Medida de error

- $MSE(x) = E_f[\hat{f}(x) - f(x)]^2.$

Si K es Gaussiano , h minimizando el error es

$$h_0 = 1.059\sigma n^{-1/5}$$

Escoger h

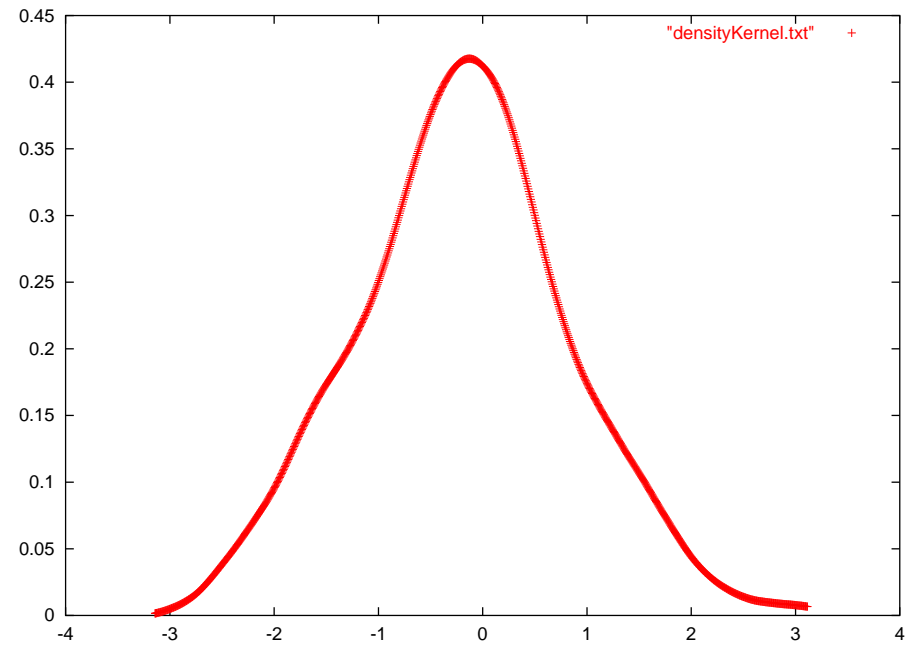
Para cualquier otro kernel K^* , el óptimo h es

$$h_{0,K^*} = C_K * h_{0,G}$$


dónde $h_{0,G}$ es el h del Kernel Gaussiano y C_K :

Kernel	C_K
<i>Epanechnikov</i>	2.214
<i>Biweight</i>	2.623
<i>Triweight</i>	2.978
<i>Uniform</i>	1.740


Uso de Kernel



Uso de Kernel



Uso de Kernel



Elvira

KernelDensity (learning/KernelDensity.java)

- *Campos*
 - *Muestra*
 - *Amplitud h (por defecto la que minimiza el error para el K gaussiano).*
 - *Kernel a usar. (por defecto gaussiano).*

KernelDensity (learning/KernelDensity.java)

- *Campos*
 - *Muestra*
 - *Amplitud h (por defecto la que minimiza el error para el K gaussiano).*
 - *Kernel a usar. (por defecto gaussiano).*
- *Métodos:*
 - *getGaussianH(Vector X): Obtiene el valor de h que minimiza el error para K Gaussiano.*
 - *assignOptimalH(): Asigna el valor de h óptimo para el kernel escogido.*
 - *getValues(Vector A): Obtiene a partir de la muestra los vectores x_1, \dots, x_m e y_1, \dots, y_m .*
 - *Constructores, métodos de acceso, etc.*

Aprendizaje Estructural

Aprendizaje estructural

- $X = \{X_1, \dots, X_n\}$
- $D = \{x^{(1)}, \dots, x^{(m)}\}$ *Muestra*
- *Objetivo: Encontrar la red Bayesiana G de variables X que mejor concuerde con D .*

Aprendizaje Estructural

Problemas a resolver:

- *Determinar una estructura candidata.*
- *Estimar las distribuciones condicionadas $\hat{\theta}$ para G .*
- *Medir la precisión de $(G, \hat{\theta})$.*

Buscar estructura

- *Buscar en el espacio de redes posibles.*
- *Simulated annealing.*
- *Empezamos con una red vacía.*
- *Operaciones permitidas:*
 - *Inserción de un arco.*
 - *Borrado de un arco.*
 - *Inversión de un arco.*
- *Tras un movimiento se reestiman las distribuciones de probabilidad.*

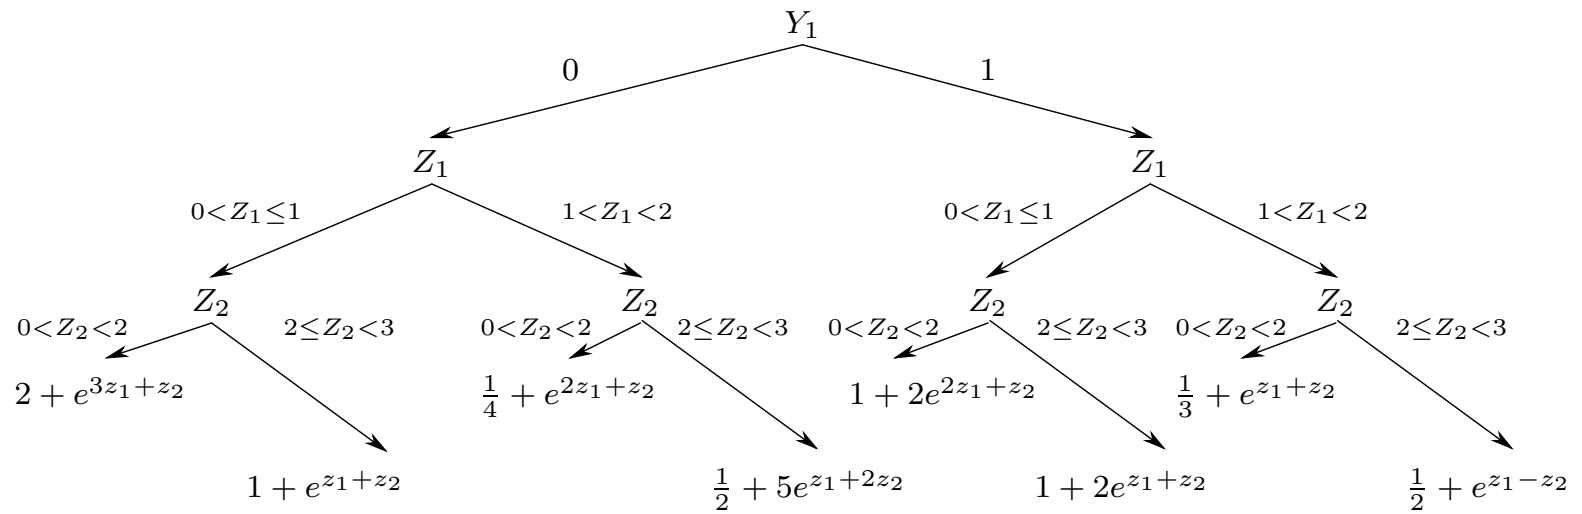
Escoger el mejor movimiento

Maximizar una medida de calidad:

$$Q(G|D, \hat{\theta}) = \log L(D; G, \hat{\theta}) - \frac{\log m}{2} \text{Dim}(G)$$

- $L(D; G, \hat{\theta})$: Verosimilitud de los datos dada la red.
- $\text{Dim}(G)$: Número de parámetros necesarios para especificar la red G .

Ejemplo



Parámetros

- k : Número de términos exponenciales en las hojas (fijo)
- $|X|$: Número de estados si X es discreta, número de trozos en los que se divide el dominio si $|X|$ es continua (fijo).
- $Par(fa(X)) = k \prod_{Y \in fa(X)} |Y|$ si X es continua.
- $Par(fa(X)) = |X| \prod_{Y \in pa(X)} |Y|$ si X es discreta.

Cortes

- s : Número de intervalos en los que se divide el dominio de variables continuas (fijo)
- $s-1$: Número de valores a estimar.
- Sólo para las variables continuas en $fa(X)$.
- Cota superior: $Spl(fa(X)) = (s - 1)^{N_c} \prod_{discretas} d_i$.
 - N_c : Número de vbles. continuas en $fa(X)$.
 - d_i : Número de estados de las vble. discreta i de $fa(X)$.

Dim(G)

-

$$Dim(G) = \sum_{i=1}^n Dim(fa(X_i))$$

-

$$Dim(fa(X)) = Par(fa(X)) + Spl(fa(X))$$

Descomposición de la métrica

$$Q(G|D, \hat{\theta}) = \sum_{j=1}^n Q(X_j|D, \hat{\theta})$$

con

$$Q(X_j|D, \hat{\theta}) = \sum_{i=1}^m \log p_j(x_j^{(i)} | pa(x_j^{(i)})) - \frac{\log m}{2} \text{Dim}(fa(X_j))$$

Sólo hay que recalcular $Q(X_j|D, \hat{\theta})$ para la vble. X_j afectada por el movimiento.

Experimentos

Experimentos

Se crearon 4 redes:

	<i>net5_1</i>	<i>net5_2</i>	<i>net10_1</i>	<i>net10_2</i>
<i>No. de enlaces</i>	6	7	13	11
<i>No. de vbles. discretas</i>	1	1	2	
<i>No. de vbles. continuas</i>	4	4	8	8

Se obtuvieron de cada red muestras de tamaño 100, 500 y 1000.

Resultados

<i>Tamaño muestra</i>	<i>100</i>	<i>500</i>	<i>1000</i>
<i>LL</i>	<i>7</i>	<i>8</i>	<i>6</i>
<i>CL</i>	<i>2</i>	<i>2</i>	<i>1</i>
<i>IL</i>	<i>3</i>	<i>3</i>	<i>1</i>
<i>NL</i>	<i>2</i>	<i>3</i>	<i>4</i>

net5_1

Resultados

<i>Tamaño muestra</i>	<i>100</i>	<i>500</i>	<i>1000</i>
<i>LL</i>	<i>7</i>	<i>5</i>	<i>8</i>
<i>CL</i>	<i>2</i>	<i>0</i>	<i>4</i>
<i>IL</i>	<i>2</i>	<i>3</i>	<i>1</i>
<i>NL</i>	<i>3</i>	<i>2</i>	<i>3</i>

net5_2

Resultados

<i>Tamaño muestra</i>	<i>100</i>	<i>500</i>	<i>1000</i>
<i>LL</i>	<i>21</i>	<i>20</i>	<i>22</i>
<i>CL</i>	<i>3</i>	<i>4</i>	<i>7</i>
<i>IL</i>	<i>4</i>	<i>2</i>	<i>3</i>
<i>NL</i>	<i>14</i>	<i>14</i>	<i>12</i>

net10_1

Resultados

<i>Tamaño muestra</i>	<i>100</i>	<i>500</i>	<i>1000</i>
<i>LL</i>	<i>15</i>	<i>25</i>	<i>23</i>
<i>CL</i>	<i>3</i>	<i>3</i>	<i>6</i>
<i>IL</i>	<i>3</i>	<i>5</i>	<i>3</i>
<i>NL</i>	<i>9</i>	<i>7</i>	<i>14</i>

net10_2

Elvira

StructuralMTELearning (learning/)

- *Campos*
 - *Database*
 - *Bnet a aprender.*

StructuralMTELearning (learning/)

- *Campos*
 - *Database*
 - *Bnet a aprender.*
- *Métodos:*
 - *structuralLearning : Aprende la red Bayesiana a partir del DatabaseCases*
 - *semiQuality(Node y, PotentialContinuousPT p) : Calcula la calidad para la vble. y.*
 - *dimension(Node var): Calcula la dimensión para la vble. var.*

Inferencia

Propagación de probabilidades

- *Operaciones de los potenciales:*
 - Restricción*
 - Multiplicación*
 - Marginalización*
 - División*

Propagación de probabilidades

- *Operaciones de los potenciales:*
 - Restricción*
 - Multiplicación*
 - Marginalización*
 - ~~*División*~~

La clase de los potenciales MTE es cerrada para restricción, multiplicación y marginalización.

Propagación de probabilidades

- *Operaciones de los potenciales:*
 - a. Restricción*
 - b. Multiplicación*
 - c. Marginalización*
 - d. ~~División~~*

La clase de los potenciales MTE es cerrada para restricción, multiplicación y marginalización.

- *Algoritmos que no requieren división:*
 - *Shenoy-Shafer.*
 - *Lazy propagation .*
 - *Eliminación de variables.*

Propagación de probabilidades

- *Operaciones de los potenciales:*
 - Restricción*
 - Multiplicación*
 - Marginalización*
 - ~~*División*~~

La clase de los potenciales MTE es cerrada para restricción, multiplicación y marginalización.

- *Algoritmos que no requieren división:*
 - *Shenoy-Shafer: Cobb and Shenoy (2003) y Cobb, Shenoy y Rumí (2004).*

Esquema Shenoy-Shafer

- *Red bayesiana*

Esquema Shenoy-Shafer

- *Red bayesiana*
- *Join Tree*


Esquema Shenoy-Shafer

- *Red bayesiana*
- *Join Tree*
- *Mensajes*



Esquema Shenoy-Shafer

- *Red bayesiana*
- *Join Tree*
- *Mensajes*
- *Distribución marginal para las variables objetivo.*



Ejemplo





Ejemplo





Ejemplo




Ejemplo



Ejemplo



Árboles mixtos



Aproximación de los árboles mixtos

- *Distancia entre árboles:*

$$D(\mathcal{T}, \mathcal{T}') = E_{\phi_{\mathcal{T}}} [(\phi_{\mathcal{T}} - \phi_{\mathcal{T}'})^2] = \int_{\Omega_{\mathbf{Z}}} \phi_{\mathcal{T}}(\mathbf{z}) (\phi_{\mathcal{T}}(\mathbf{z}) - \phi_{\mathcal{T}'}(\mathbf{z}))^2 d\mathbf{z}$$

Aproximación de los árboles mixtos

- *Distancia entre árboles:*

$$D(\mathcal{T}, \mathcal{T}') = E_{\phi_{\mathcal{T}}} [(\phi_{\mathcal{T}} - \phi_{\mathcal{T}'})^2] = \int_{\Omega_{\mathbf{Z}}} \phi_{\mathcal{T}}(\mathbf{z}) (\phi_{\mathcal{T}}(\mathbf{z}) - \phi_{\mathcal{T}'}(\mathbf{z}))^2 d\mathbf{z}$$

- *Disminuir el número de términos exponenciales.*

Aproximación de los árboles mixtos

- *Distancia entre árboles:*

$$D(\mathcal{T}, \mathcal{T}') = E_{\phi_{\mathcal{T}}} [(\phi_{\mathcal{T}} - \phi_{\mathcal{T}'})^2] = \int_{\Omega_{\mathbf{Z}}} \phi_{\mathcal{T}}(\mathbf{z}) (\phi_{\mathcal{T}}(\mathbf{z}) - \phi_{\mathcal{T}'})^2 d\mathbf{z}$$

- *Disminuir el número de términos exponenciales.*
- *Disminuir el número de hojas:*

Aproximación de los árboles mixtos

- *Distancia entre árboles:*

$$D(\mathcal{T}, \mathcal{T}') = E_{\phi_{\mathcal{T}}} [(\phi_{\mathcal{T}} - \phi_{\mathcal{T}'})^2] = \int_{\Omega_{\mathbf{Z}}} \phi_{\mathcal{T}}(\mathbf{z}) (\phi_{\mathcal{T}}(\mathbf{z}) - \phi_{\mathcal{T}'}(\mathbf{z}))^2 d\mathbf{z}$$

- *Disminuir el número de términos exponenciales.*
- *Disminuir el número de hojas:*
 - *Unir dos hijos (de una vble. continua).*

Aproximación de los árboles mixtos

- *Distancia entre árboles:*

$$D(\mathcal{T}, \mathcal{T}') = E_{\phi_{\mathcal{T}}} [(\phi_{\mathcal{T}} - \phi_{\mathcal{T}'})^2] = \int_{\Omega_{\mathbf{Z}}} \phi_{\mathcal{T}}(\mathbf{z}) (\phi_{\mathcal{T}}(\mathbf{z}) - \phi_{\mathcal{T}'}(\mathbf{z}))^2 d\mathbf{z}$$

- *Disminuir el número de términos exponenciales.*
- *Disminuir el número de hojas:*
 - *Unir dos hijos (de una vble. continua).*
 - *Podar variables discretas.*

Aproximación de los árboles mixtos

- *Distancia entre árboles:*

$$D(\mathcal{T}, \mathcal{T}') = E_{\phi_{\mathcal{T}}} [(\phi_{\mathcal{T}} - \phi_{\mathcal{T}'})^2] = \int_{\Omega_{\mathbf{Z}}} \phi_{\mathcal{T}}(\mathbf{z}) (\phi_{\mathcal{T}}(\mathbf{z}) - \phi_{\mathcal{T}'}(\mathbf{z}))^2 d\mathbf{z}$$

- *Disminuir el número de términos exponenciales.*
- *Disminuir el número de hojas:*
 - *Unir dos hijos (de una vble. continua).*
 - *Podar variables discretas.*
- *Podamos sólo si $D(\mathcal{T}, \mathcal{T}') < \varepsilon$.*

Disminuir el número de términos exponenciales

$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}}$$

Disminuir el número de términos exponenciales

$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}} \rightarrow p_i = \int_{\Omega_{\mathbf{z}}} a_i e^{b_i \mathbf{z}} d\mathbf{z}$$

Disminuir el número de términos exponenciales

$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}} \rightarrow p_i = \int_{\Omega_{\mathbf{z}}} a_i e^{b_i \mathbf{z}} d\mathbf{z}$$

- $k = \text{Número de términos exponenciales}$

Disminuir el número de términos exponenciales

$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}} \rightarrow p_i = \int_{\Omega_{\mathbf{z}}} a_i e^{b_i \mathbf{z}} d\mathbf{z}$$

- $k =$ Número de términos exponenciales
- Mientras $k > 2$ (o parámetro fijado)

Disminuir el número de términos exponenciales

$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}} \rightarrow p_i = \int_{\Omega_{\mathbf{z}}} a_i e^{b_i \mathbf{z}} d\mathbf{z}$$

- $k =$ Número de términos exponenciales
- Mientras $k > 2$ (o parámetro fijado)
 - Eliminar $a_i e^{b_i \mathbf{z}}$ si $|p_i| = \min_j |p_j|$

Disminuir el número de términos exponenciales

$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}} \rightarrow p_i = \int_{\Omega_{\mathbf{z}}} a_i e^{b_i \mathbf{z}} d\mathbf{z}$$

- $k =$ Número de términos exponenciales
- Mientras $k > 2$ (o parámetro fijado)
 - Eliminar $a_i e^{b_i \mathbf{z}}$ si $|p_i| = \min_j |p_j|$
 - Actualizar resto de términos.

Disminuir el número de términos exponenciales


$$f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}} \rightarrow p_i = \int_{\Omega_{\mathbf{z}}} a_i e^{b_i \mathbf{z}} d\mathbf{z}$$

- $k =$ Número de términos exponenciales
- Mientras $k > 2$ (o parámetro fijado)
 - Eliminar $a_i e^{b_i \mathbf{z}}$ si $|p_i| = \min_j |p_j|$
 - Actualizar resto de términos.
 - $k = k-1$.



Actualizar:

Se calcula el máximo valor del término, $m = \max_{z \in \mathbf{Z}} \{a_i e^{b_i z}\}$, y se suma al término independiente, $k^ = k + m$, para posteriormente normalizar.*

Unir dos intervalos



Unir dos intervalos





Unir dos intervalos



$$p_{j_1} = \int_{\Omega_{\mathbf{Z}}} f_{j_1}(\mathbf{z}) d\mathbf{z} \quad \text{y} \quad p_{j_2} = \int_{\Omega_{\mathbf{Z}}} f_{j_2}(\mathbf{z}) d\mathbf{z}$$

Unir dos intervalos



$$p_{j_1} = \int_{\Omega_{\mathbf{Z}}} f_{j_1}(\mathbf{z}) d\mathbf{z} \quad \text{y} \quad p_{j_2} = \int_{\Omega_{\mathbf{Z}}} f_{j_2}(\mathbf{z}) d\mathbf{z}$$

$$f(\mathbf{z}) = \frac{p_{j_1} f_{j_1}(\mathbf{z}) + p_{j_2} f_{j_2}(\mathbf{z})}{p_{j_1} + p_{j_2}}$$

Unir dos intervalos



$$p_{j_1} = \int_{\Omega_{\mathbf{Z}}} f_{j_1}(\mathbf{z}) d\mathbf{z} \quad \text{y} \quad p_{j_2} = \int_{\Omega_{\mathbf{Z}}} f_{j_2}(\mathbf{z}) d\mathbf{z}$$

$$f(\mathbf{z}) = \frac{p_{j_1} f_{j_1}(\mathbf{z}) + p_{j_2} f_{j_2}(\mathbf{z})}{p_{j_1} + p_{j_2}}$$

$$\int_{\Omega_{\mathbf{Z}}} K f(\mathbf{z}) d\mathbf{z} = p_{j_1} + p_{j_2}$$

Unir dos intervalos




$$p_{j_1} = \int_{\Omega_{\mathbf{Z}}} f_{j_1}(\mathbf{z}) d\mathbf{z} \quad \text{y} \quad p_{j_2} = \int_{\Omega_{\mathbf{Z}}} f_{j_2}(\mathbf{z}) d\mathbf{z}$$



$$f(\mathbf{z}) = \frac{p_{j_1} f_{j_1}(\mathbf{z}) + p_{j_2} f_{j_2}(\mathbf{z})}{p_{j_1} + p_{j_2}}$$

$$\int_{\Omega_{\mathbf{Z}}} K f(\mathbf{z}) d\mathbf{z} = p_{j_1} + p_{j_2} \quad \Rightarrow \quad K = \frac{p_{j_1} + p_{j_2}}{\int_{\Omega_{\mathbf{Z}}} f(\mathbf{z}) d\mathbf{z}}$$



Poda de variables discretas



Poda de variables discretas





Poda de variables discretas



$$DK(p,q) = \sum_i p_i \log\left(\frac{p_i}{q_i}\right)$$

Poda de variables discretas



$$DK(p,q) = \sum_i p_i \log\left(\frac{p_i}{q_i}\right)$$

$$\xi = -((0.5 - \varepsilon) \log(0.5 - \varepsilon) + (0.5 + \varepsilon) \log(0.5 + \varepsilon))$$

Podamos si $DK(\phi, \bar{p}) < \xi$

Experimentos

Propagación

- *Redes creadas:*

<i>Net</i>	<i>N. nodos</i>	<i>N. nodos discretos</i>
<i>Net1</i>	<i>42</i>	<i>3</i>
<i>Net2</i>	<i>77</i>	<i>8</i>
<i>Net3</i>	<i>86</i>	<i>11</i>

Propagación

- *Redes creadas:*
- *Evidencia: 30 % de las variables.*

Propagación

- *Redes creadas:*
- *Evidencia: 30 % de las variables.*
- *Comparamos con la discretización. Cada función MTE $f(\mathbf{z}) = k + \sum_{i=1}^n a_i e^{b_i \mathbf{z}}$ se reemplaza por una constante $f^*(\mathbf{z}) = k^*$ tal que*

$$\int_{\Omega_{\mathbf{z}}} f(\mathbf{z}) d\mathbf{z} = \int_{\Omega_{\mathbf{z}}} f^*(\mathbf{z}) d\mathbf{z} .$$

Propagación


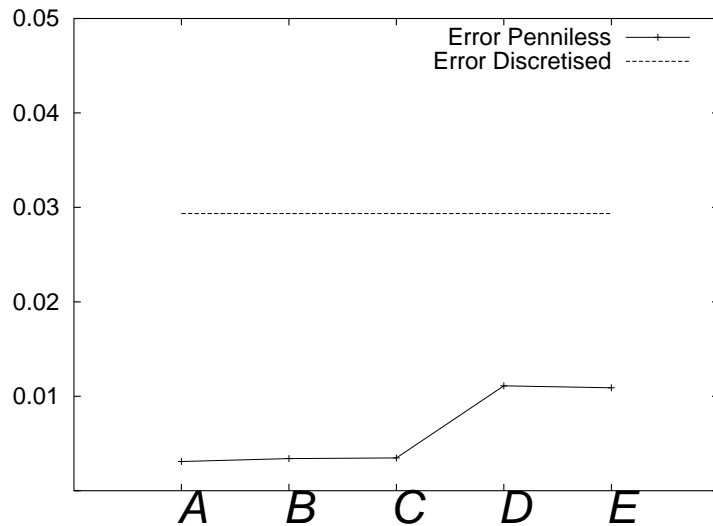
- *Redes creadas:*
- *Evidencia: 30 % de las variables.*
- *Comparamos con la discretización.*
- *Estadísticos de la propagación: Para cada vble. no observada se calcula*
 - *Tamaño del máximo potencial necesario para calcular la distribución marginal.*
 - *Error asociado.*

Se presenta la media de estas cantidades.

Parámetros de poda



<i>Poda</i>	<i>Parámetro unión</i>	<i>Parámetro discreto</i>
<i>A</i>	<i>0</i>	<i>0</i>
<i>B</i>	<i>0.005</i>	<i>0</i>
<i>C</i>	<i>0.005</i>	<i>0.01</i>
<i>D</i>	<i>0.05</i>	<i>0</i>
<i>E</i>	<i>0.05</i>	<i>0.01</i>

Resultados



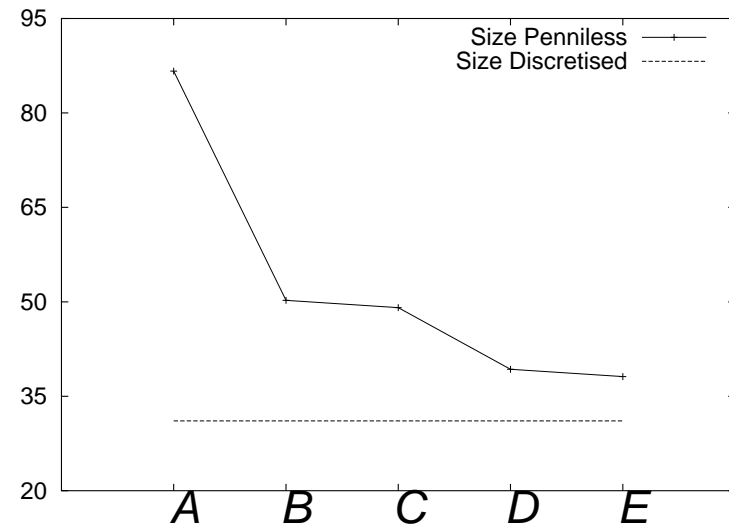
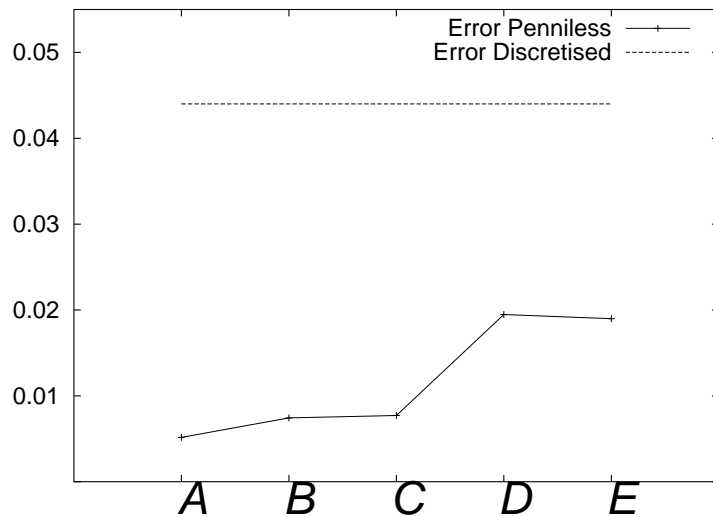
Errores y tamaños para Net1

Resultados



Errores y tamaños para Net2

Resultados



Errores y tamaños para Net3

Elvira

MTESimplePenniless (inference/clustering)

- *Hereda de SimplePenniless.*
 - *propagate(String resultFile, double epsilonJoin, double epsilonDisc, Evidence e, Vector sizeVec, int prune2Int):*
Realiza la propagación y guarda el resultado en el fichero resultFile como una red Bayesiana.
 - *Mismos métodos que SimplePenniless pero «actualizados» para trabajar con MTEs.*

PotentialContinuousPT (potential/)

- *Métodos de poda:*
 - *prune*
 - *prune2*

ContinuousProbabilityTree (potential/)

- *Métodos de poda:*
 - *prune*
 - *pruneIterative*
 - *pruneTerms*
 - *pruneJoin*
 - *pruneDiscrete*
 - *prune2*
 - *ErrorPruning*

En curso

Trabajos actuales

- *Mejora del proceso de selección de la partición del dominio de vbles. continuas en el aprendizaje de distribuciones condicionadas.*
- *Algoritmo de muestreo por importancia :
¿ $P(X \in (a, b))$?*

Trabajos actuales

- *Mejora del proceso de selección de la partición del dominio de vbles. continuas en el aprendizaje de distribuciones condicionadas.*
- *Algoritmo de muestreo por importancia :
¿ $P(X \in (a, b))$?*

Trabajos actuales

- *Mejora del proceso de selección de la partición del dominio de vbles. continuas en el aprendizaje de distribuciones condicionadas.*
- *Algoritmo de muestreo por importancia :
¿ $P(X \in (a, b))$?*

Trabajos actuales

- *Mejora del proceso de selección de la partición del dominio de vbles. continuas en el aprendizaje de distribuciones condicionadas.*
- *Algoritmo de muestreo por importancia :
¿ $P(X \in (a, b))$?*

Trabajos actuales

- *Mejora del proceso de selección de la partición del dominio de vbles. continuas en el aprendizaje de distribuciones condicionadas.*
- *Algoritmo de muestreo por importancia :
¿ $P(X \in (a, b))$?*