

Tema 6: Clasificadores Bayesianos

Pedro Larrañaga, Iñaki Inza, Abdelmalik Moujahid

Departamento de Ciencias de la Computación e Inteligencia Artificial

Universidad del País Vasco

<http://www.sc.ehu.es/isg/>

Modelos básicos

- Naïve Bayes (Minsky, 1961)
- Seminaïve Bayes (Pazzani, 1997)
- Naïve Bayes aumentado a árbol (Friedman y col., 1997)
- Clasificador Bayesiano k -dependiente (Sahami, 1996)
- Red Bayesiana (Jensen, 2001)

Clasificadores Bayesianos

Clasificación Supervisada con Paradigmas Probabilistas

$$\gamma : (x_1, \dots, x_n) \rightarrow \{1, 2, \dots, r_0\}$$

- Matriz de costes: $co(r, s)$
- Minimización del coste total de errores

$$\gamma(\mathbf{x}) = \arg \min_k \sum_{c=1}^{r_0} co(k, c) p(c|x_1, \dots, x_n)$$

- Función de pérdida 0/1

$$\gamma(\mathbf{x}) = \arg \max_c p(c|x_1, \dots, x_n)$$

Naïve Bayes

Formulación clásica de un problema de diagnóstico

- m diagnósticos posibles no excluyentes

	X_1	$\dots$	X_n	Y_1	$\dots$	Y_m
$(\mathbf{x}^{(1)}, \mathbf{y}^{(1)})$	$x_1^{(1)}$	$\dots$	$x_n^{(1)}$	$y_1^{(1)}$	$\dots$	$y_m^{(1)}$
$(\mathbf{x}^{(2)}, \mathbf{y}^{(2)})$	$x_1^{(2)}$	$\dots$	$x_n^{(2)}$	$y_1^{(2)}$	$\dots$	$y_m^{(2)}$
$\dots$		$\dots$			$\dots$	
$(\mathbf{x}^{(N)}, \mathbf{y}^{(N)})$	$x_1^{(N)}$	$\dots$	$x_n^{(N)}$	$y_1^{(N)}$	$\dots$	$y_m^{(N)}$

Naïve Bayes

Formulación clásica de un problema de diagnóstico

$$(y_1^*, \dots, y_m^*) = \arg \max_{(y_1, \dots, y_m)} p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n)$$

$$p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n)$$

$$\propto p(Y_1 = y_1, \dots, Y_m = y_m) p(X_1 = x_1, \dots, X_n = x_n | Y_1 = y_1, \dots, Y_m = y_m)$$

número de parámetros a estimar: $2^m - 1 + 2^m(2^n - 1)$

m	n	parámetros	
3	10	$\simeq$	$8 \cdot 10^3$
5	20	$\simeq$	$33 \cdot 10^6$
10	50	$\simeq$	$11 \cdot 10^{17}$

Naïve Bayes

Diagnósticos excluyentes

$$c^* = \arg \max_c p(C = c | X_1 = x_1, \dots, X_n = x_n)$$

$$p(C = c | X_1 = x_1, \dots, X_n = x_n) \propto p(C = c) p(X_1 = x_1, \dots, X_n = x_n | C = c)$$

número de parámetros a estimar: $(r_0 - 1) + r_0(2^n - 1)$

r_0	n		parámetros
3	10	$\simeq$	$3 \cdot 10^3$
5	20	$\simeq$	$5 \cdot 10^6$
10	50	$\simeq$	$11 \cdot 10^{15}$

Naïve Bayes

Diagnósticos excluyentes y variables condicionalmente independientes dado el diagnóstico (naïve Bayes)

$$c^* = \arg \max_c p(C = c | X_1 = x_1, \dots, X_n = x_n)$$

$$= \arg \max_c p(C = c) \prod_{i=1}^n p(X_i = x_i | C = c)$$

número de parámetros a estimar: $(r_0 - 1) + r_0 n$

r_0	n	parámetros
3	10	32
5	20	104
10	50	509

Naïve Bayes

Naïve Bayes (Minsky, 1961)

- Variables predictoras condicionalmente independientes dada C
 - Predictoras discretas


$$c^* = \arg \max_c p(C = c) \prod_{i=1}^n p(X_i = x_i | C = c)$$

- Predictoras continuas y normales

$$c^* = \arg \max_c p(C = c) \prod_{i=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma_i^c} e^{-\frac{1}{2} \left(\frac{x_i - \mu_i^c}{\sigma_i^c} \right)^2} \right]$$

Naïve Bayes

Naïve Bayes



Estructura gráfica de un modelo naïve Bayes

Seminaive Bayes

Paso 1. Inicializar el conjunto de variables a utilizar a vacío.
Clasificar todos los ejemplos como pertenecientes a la clase más frecuente

Paso 2. **Repetir** en cada paso la mejor opción entre:

(a) Considerar cada variable que no está en el modelo como una variable a incluir en el modelo. Dicha variable debe incluirse condicionalmente independiente de las variables presentes en el modelo, dada la variable clase

(b) Juntar cada variable no presente en el modelo con una variable que ya forme parte del mismo


Evaluar cada posible opción por medio de la estimación del porcentaje de bien clasificados

Hasta que ninguna opción produzca mejoras

Pseudocódigo del algoritmo *FSSJ* (Pazzani, 1997)

Seminaïve Bayes

Seminaïve Bayes



Proceso de construcción de un modelo seminaïve Bayes.

$$p(c|x, y, z, v) \propto p(c)p(z|c)p((y, v)|c)$$

Naïve Bayes aumentado a árbol

- Cantidad de información mutua entre X e Y

$$I(X, Y) = \sum_{i=1}^{r_X} \sum_{j=1}^{r_Y} p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}$$

mide la reducción de la incertidumbre de una de las variables cuando se conoce la otra

- Cantidad de información mutua entre X e Y condicionada a C

$$\begin{aligned} I(X, Y|C) &= \sum_c p(c) I(X, Y|C = c) \\ &= \sum_{i=1}^{r_X} \sum_{j=1}^{r_Y} \sum_{k=1}^{r_0} p(x_i, y_j, c_k) \log \frac{p(x_i, y_j|c_k)}{p(x_i|c_k)p(y_j|c_k)} \end{aligned}$$

- Relación entre la cantidad de información mutua y la verosimilitud

Naïve Bayes aumentado a árbol

Paso 1. Calcular $I(X_i, X_j | C)$ con $i < j, i, j = 1, \dots, n$

Paso 2. Construir un grafo no dirigido completo cuyos nodos corresponden a las variables predictoras: $X_1, \dots, X_n$. Asignar a cada arista conectando las variables X_i y X_j un peso dado por $I(X_i, X_j | C)$

Paso 3. Asignar las dos aristas de mayor peso al árbol a construir

Paso 4. Examinar la siguiente arista de mayor peso, y añadirla al árbol a no ser que forme un ciclo, en cuyo caso se descarta y se examina la siguiente arista de mayor peso









Paso 5. Repetir el paso 4 hasta seleccionar $n - 1$ aristas

Paso 6. Transformar el árbol no dirigido resultante en uno dirigido escogiendo una variable como raíz, para a continuación direccionar el resto de aristas

Paso 7. Construir un modelo TAN añadiendo un nodo etiquetado como C y posteriormente un arco desde C a cada variable predictora X_i

Pseudocódigo del algoritmo TAN (Friedman y col., 1997)

Naïve Bayes aumentado a árbol



Proceso de construcción de TAN. $I(X, Z|C) > I(Y, V|C) > I(X, Y|C) > I(Z, V|C) >$

$I(X, V|C) > I(Z, W|C) > I(X, W|C) > I(Y, Z|C) > I(Y, W|C) > I(V, W|C)$


$$p(c|x, y, z, v, w) \propto p(c)p(x|c)p(y|x, c)p(z|x, c)p(v|y, c)p(w|z, c)$$

Clasificador Bayesiano k -dependiente

Clasificador Bayesiano k -dependiente (Sahami, 1996)

- Precalcula $I(X_i, C)$ y $I(X_i, X_j|C)$ para todo par de variables
- Añade en cada iteración, de entre las variables que no están en el modelo, aquella X_{max} que tenga mayor $I(X_i, C)$
- Asigna a la variable añadida como padres la variable C y aquellas k variables con mayor $I(X_j, X_{max}|C)$



Clasificador Bayesiano k -dependiente



Proceso de construcción de k DB con $k = 2$.

$$\begin{aligned} &I(X_3, C) > I(X_1, C) > I(X_4, C) > I(X_5, C) > I(X_2, C) \\ &I(X_3, X_4|C) > I(X_2, X_5|C) > I(X_1, X_3|C) > I(X_1, X_2|C) > I(X_2, X_4|C) > \\ &I(X_2, X_3|C) > I(X_1, X_4|C) > I(X_4, X_5|C) > I(X_1, X_5|C) > I(X_3, X_5|C) \end{aligned}$$



Clasificador Bayesiano k -dependiente



Proceso de construcción de k DB con $k = 2$.

$$\begin{aligned}
 &I(X_3, C) > I(X_1, C) > I(X_4, C) > I(X_5, C) > I(X_2, C) \\
 &I(X_3, X_4|C) > I(X_2, X_5|C) > I(X_1, X_3|C) > I(X_1, X_2|C) > I(X_2, X_4|C) > \\
 &I(X_2, X_3|C) > I(X_1, X_4|C) > I(X_4, X_5|C) > I(X_1, X_5|C) > I(X_3, X_5|C) \\
 &p(c|x_1, x_2, x_3, x_4, x_5)
 \end{aligned}$$

Clasificador Bayesiano k -dependiente



Proceso de construcción de k DB con $k = 2$.

$$I(X_3, C) > I(X_1, C) > I(X_4, C) > I(X_5, C) > I(X_2, C)$$


$$I(X_3, X_4|C) > I(X_2, X_5|C) > I(X_1, X_3|C) > I(X_1, X_2|C) > I(X_2, X_4|C) >$$

$$I(X_2, X_3|C) > I(X_1, X_4|C) > I(X_4, X_5|C) > I(X_1, X_5|C) > I(X_3, X_5|C)$$

$$p(c|x_1, x_2, x_3, x_4, x_5) \propto$$

$$p(c)p(x_1|x_3, c)p(x_2|x_1, x_5, c)p(x_3|c)p(x_4|x_1, x_3, c)p(x_5|x_1, x_4, c)$$

Red Bayesiana múltiplemente conectada



$$\begin{aligned} p(X_1 = 0) &= 0,20 & p(X_4 = 0 | X_2 = 0, X_3 = 0) &= 0,80 \\ p(X_2 = 0 | X_1 = 0) &= 0,80 & p(X_4 = 0 | X_2 = 1, X_3 = 0) &= 0,80 \\ p(X_2 = 0 | X_1 = 1) &= 0,80 & p(X_4 = 0 | X_2 = 0, X_3 = 1) &= 0,80 \\ p(X_3 = 0 | X_1 = 0) &= 0,20 & p(X_4 = 0 | X_2 = 1, X_3 = 1) &= 0,05 \\ p(X_3 = 0 | X_1 = 1) &= 0,05 & p(X_5 = 0 | X_3 = 0) &= 0,80 \\ & & p(X_5 = 0 | X_3 = 1) &= 0,60 \end{aligned}$$

Factorización de la distribución de probabilidad conjunta obtenida con la red Bayesiana adjunta