

Algoritmo TM aplicado a modelos gráficos probabilísticos

Grupo de Sistemas Inteligentes

Departamento de Ciencias de la Computación e Inteligencia Artificial

Universidad del País Vasco

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

Reunión ELVIRA. Mayo 2003

Indice

- Introducción
- Introducción al algoritmo TM
- El algoritmo TM en familias exponenciales
- Aplicación del algoritmo TM en modelos gráficos probabilísticos: un ejemplo

Introducción

Medidas para aprender un clasificador basado en MGPs:

- Basadas en verosimilitud conjunta $p(c, \mathbf{x})$
- Basadas en verosimilitud condicionada $p(c|\mathbf{x})$
- Basadas en la teoría de la información
- Basadas en estimaciones del % de bien clasificados

Distinción: generativos versus discriminativos

Introducción al algoritmo TM

- Introducido por Edwards y Lauritzen (2001) (Biometrika)
- Objetivo: optimizar una verosimilitud condicional cuando la conjunta es más fácil de optimizar
- Resultados sobre convergencia: Sundberg (2002) (Biometrika)
- Similitud con el algoritmo EM, se aumentan los parámetros en lugar de los datos
- Consta de dos pasos: el paso T y el paso M

Introducción al algoritmo TM

$$l(\theta) = \log p(x, c|\theta) \quad l_x(\theta) = \log p(x|\theta) \quad l^x(\theta) = \log p(c|x, \theta)$$

- En el paso T se construye la función $q(\theta)$:

$$\begin{aligned} q(\theta) = q(\theta|\theta_r) &= l(\theta) - \theta^T \dot{l}_x(\theta_r) \\ &= l(\theta) - \theta^T E_{\theta_r} \left[\dot{l}(\theta_r) | x \right] \end{aligned}$$

- La función anterior es una aproximación a la verosimilitud condicional ($l^x = l - l_x$)

Introducción al algoritmo TM

- El paso M consiste en la maximización en θ de la función $q(\theta|\theta_r)$:

$$E_{\theta_r} [l(\theta_r)|x] = l(\theta)$$

- El algoritmo se puede escribir como:

$$\theta_0 = \arg \max_{\theta} l(\theta) \quad \theta_{r+1} = \arg \max_{\theta} q(\theta|\theta_r)$$

TM en la familia exponencial

- La verosimilitud conjunta se puede escribir como $(\theta = (\alpha, \beta))$:

$$l(\theta) = \alpha^T u(c, x) + \beta^T v(x) - \psi(\alpha, \beta)$$

con

$$\psi(\alpha, \beta) = \log \int \exp [\alpha^T u(c, x) + \beta^T v(x)] \mu(dc|x) \mu dx$$

TM en la familia exponencial

- Definimos dos nuevas funciones de variables aleatorias: $\mathcal{U} = u(C, X)$ y $\mathcal{V} = v(X)$
- Las estimaciones máximo verosímiles $\hat{\theta}$ de los parámetros θ se obtienen al resolver las ecuaciones:

$$E_{\theta}[\mathcal{U}] = u(c, x) \quad E_{\theta}[\mathcal{V}] = v(x)$$

TM en la familia exponencial

- El algoritmo queda como sigue:

$$u_{r+1} = u_r + u - E_{\theta_r}[\mathcal{U}|x] \text{ con } u_0 = u(c, x)$$

$$\theta_{r+1} = \hat{\theta}(u_{r+1}, v)$$

- Como primer conjunto de parámetros θ_0 se toman los estimadores máximo verosímiles

Algoritmo TM en MGPs

- Veamos un ejemplo con el Naive-Bayes con variables binarias
- Modelo condicional:

$$\begin{aligned} p(c|x) &= \frac{p(c, x)}{p(x)} = \frac{p(c) \prod_{i=1}^n p(x_i|c)}{p(x)} \\ &= \frac{p(c) \prod_{i=1}^n p(x_i|c)}{p(c) \prod_{i=1}^n p(x_i|c) + p(\bar{c}) \prod_{i=1}^n p(x_i|\bar{c})} \end{aligned}$$

Algoritmo TM en MGPs

- Introducimos el modelo condicional en un modelo conjunto:

$$p(c, x) = \frac{1}{(p(c))^{n-1}} \prod_{i=1}^n p(x_i, c)$$

Algoritmo TM en MGPs

- Finalmente puede expresarse en función de los parámetros conjuntos:

$$\begin{aligned}
 p(c, x) &= (p(C = 0)^{(1-c)}(1 - p(C = 0))^c)^{-(n-1)} \\
 &\quad \prod_{i=1}^n [p(C = 0, X_i = 0)^{(1-c)(1-x_i)} p(C = 0, X_i = 1)^{(1-c)} \\
 &\quad p(C = 1, X_i = 0)^{c(1-x_i)} p(C = 1, X_i = 1)^{cx_i}] \\
 &= \exp \left\{ \log \left((p(C = 0)^{(1-c)}(1 - p(C = 0))^c)^{-(n-1)} \right. \right. \\
 &\quad \left. \left. \prod_{i=1}^n [p(C = 0, X_i = 0)^{(1-c)(1-x_i)} p(C = 0, X_i = 1)^{(1-c)} \right. \right. \\
 &\quad \left. \left. p(C = 1, X_i = 0)^{c(1-x_i)} p(C = 1, X_i = 1)^{cx_i}] \right) \right\} .
 \end{aligned}$$

Algoritmo TM en MGPs

- Expresamos la log-verosimilitud conjunta como en la familia exponencial: $l(\theta)$

$$\begin{aligned} &= \sum_{k=1}^N c^{(k)} ((n-1)(\log(p(C=0)) - \log(1-p(C=0)))) \\ &+ \sum_{k=1}^N \sum_{i=1}^n c^{(k)} x_i^{(k)} (\log(p(C=0, X_i=0)) - \log(p(C=1, X_i=1))) \\ &- \sum_{k=1}^N \sum_{i=1}^n c^{(k)} x_i^{(k)} (\log(p(C=0, X_i=1)) - \log(p(C=1, X_i=0))) \\ &+ \sum_{k=1}^N \sum_{i=1}^n x_i^{(k)} (\log(p(C=0, X_i=1)) - \log(p(C=0, X_i=0))) \\ &+ N \left(\sum_{i=1}^n \log(p(C=0, X_i=0)) - (n-1) \log(p(C=0)) \right) \end{aligned}$$

Algoritmo TM en MGPs

- Identificando términos obtengo los siguientes valores:

$$\mathcal{U} = u(C, X) = \left(\sum_{k=1}^N C^{(k)}, \sum_{k=1}^N C^{(k)} X_1^{(k)}, \dots, \sum_{k=1}^N C^{(k)} X_n^{(k)} \right)$$
$$\mathcal{V} = v(X) = \left(\sum_{k=1}^N X_1^{(k)}, \dots, \sum_{k=1}^N X_n^{(k)} \right)$$

Algoritmo TM en MGPs

- Los estadísticos suficientes a considerar son:

$$\mathcal{U} = (N_0, N_{01}, \dots, N_{0i}, \dots, N_{0n})$$

$$\mathcal{V} = (N_1, \dots, N_i, \dots, N_n)$$

Algoritmo TM en MGPs

- Para completar el algoritmo debemos calcular $E_{\theta_r}[\mathcal{U}|x]$:

$$E_{\theta_r}[N_0|x] = \sum_{k=1}^N E_{\theta_r}[C^{(k)}|x] = \sum_{k=1}^N p_{\theta_r}(C = 1|X = x^{(k)})$$

$$\begin{aligned} E_{\theta_r}[N_{0i}|x] &= \sum_{k=1}^N E_{\theta_r}[C^{(k)} X_i^{(k)}|x] \\ &= \sum_{k=1}^N p_{\theta_r}(C = 1|X = x^{(k)}) x_i^{(k)} \quad i = 1, \dots, n \end{aligned}$$

Algoritmo TM en MGPs

- En el cálculo anterior se utilizaron probabilidades condicionadas estas se calculan como:

$$p_r(C = 1) = \frac{N_{0,(r)}}{N}$$

$$p_r(X_i = 1|C = 1) = \frac{N_{0i,(r)}}{N_{0,(r)}}$$

$$p_r(X_i = 1|C = 0) = \frac{N_i - N_{0i,(r)}}{N - N_{0,(r)}}$$

Algoritmo TM en MGPs

- i) A partir de $N_{0,(r)}$ y $N_{0i,(r)}$ calcular las probabilidades: $p_{(r)}(C = 1)$ y $p_{(r)}(X_i = 1 | C = c)$
- ii) Utilizando las probabilidades anteriores calcular las esperanzas de los estadísticos suficientes condicionadas a la muestra: $E_{\theta_r}[N_0|x]$ y $E_{\theta_r}[N_{0i}|x]$
- iii) Calcular los nuevos estadísticos suficientes mediante la fórmula: $u_{r+1} = u_r + u - E_{\theta_r}[\mathcal{U}|x]$ siendo $u_r = (N_{0,(r)}, N_{01,(r)}, \dots, N_{0n,(r)})$