

# Introducción a *Markov Logic Networks*

Franco M. Luque

- ▶ Una *first-order knowledge base (KB)* es:
  - ▶ conjuntos de nombres de constantes, funciones (+aridad) y predicados (+aridad)
  - ▶ y un conjunto de fórmulas en lógica de primer orden con estos elementos.
- ▶ Problema de inferencia: ¿Vale  $F$  para todo mundo posible de  $KB$ ?
- ▶ Pasamos las fórmulas a *conjunctive normal form (CNF)*. Las variables libres implícitamente están cuantificadas con  $\forall$ .
- ▶ Suponemos entonces que cada fórmula es una disjunción de literales.

- ▶ Asignamos a cada fórmula  $F_i$  un peso  $w_i$  (esta será la definición de MLN).
- ▶ Ahora los mundos posibles serán más o menos probables dependiendo de cuántas fórmulas de la KB respeten.
- ▶ Problema de inferencia: ¿Cuál es la prob. de  $F_1$  dado que vale  $F_2$ ?:

$$P(F_1|F_2) = \frac{\sum_{x \in \mathcal{X}_{F_1} \cap \mathcal{X}_{F_2}} P(X = x)}{\sum_{x \in \mathcal{X}_{F_2}} P(X = x)}$$

- ▶ Falta definir  $P(X = x)$ , a donde  $x$  es un mundo posible.

- ▶ Tenemos  $L = \{(F_i, w_i)\}$  (la MLN) y las cttes.  
 $C = \{c_1, \dots, c_{|C|}\}$
- ▶ Suposiciones:
  1. Nombres únicos: cada ctte. es un elemento distinto.
  2. Dominio cerrado: todo elemento es alguna constante.
  3. Funciones conocidas: se conocen las funciones.
- ▶ Ahora un mundo posible  $x$  es una “interpretación” de los predicados. Hacemos  $x = (x_1, \dots, x_n)$ , a dónde cada  $x_i$  indicará el valor booleano de un predicado aplicado a una tupla de cttes. (esto es, un *ground atom*).
- ▶ El problema se convierte en modelar la distribución conjunta de un vector de variables aleatorias binarias.

- ▶ Un *grounding* de una fórmula  $F$  es la fórmula asignando valores concretos (cttes.) a las variables.
- ▶ Dada una fórmula  $F$  y un mundo posible  $x$ , podemos contar cuántos *groundings* de  $F$  dan verdaderos suponiendo  $x$ .
- ▶ Modelamos


$$P(X = x) = \frac{1}{Z} \exp\left(\sum_i w_i n_i(x)\right)$$

a donde  $n_i(x)$  es la cantidad de *groundings* verdaderos de  $F_i$  en  $x$  (y  $Z = \sum_x \exp(\sum_i w_i n_i(x))$ ).

- ▶ El modelo propuesto es una instancia de *Markov Networks*.
- ▶ Para trabajar con el modelo definimos un grafo  $G$  con un nodo por variable  $X_i$ , es decir, por *ground atom*.
- ▶ Cada *grounding* de una fórmula conecta todos los nodos de los *ground atoms* que lo componen.
- ▶ La colcha de Markov o *Markov blanket* de un nodo  $X_i$  son sus nodos vecinos, es decir, los nodos que aparecen con  $X_i$  en algún *grounding* de alguna fórmula de la MLN.

## Bue, esta bien, un ejemplo:

- ▶ Predicados  $Sm$  (fuma),  $Ca$  (tiene cancer),  $Fr$  (son amigos):
  1.  $F_1 = \forall x Sm(x) \Rightarrow Ca(x)$ ,  $w_1 = 1, 5$ .
  2.  $F_2 = \forall x \forall y Fr(x, y) \Rightarrow (Sm(x) \Leftrightarrow Sm(y))$ ,  $w_2 = 2, 2$ .
- ▶ En CNF:
  1.  $F_1 = \neg Sm(x) \vee Ca(x)$ ,  $w_1 = 1, 5$ .
  2.  $F_2 = \neg Fr(x, y) \vee Sm(x) \vee \neg Sm(y)$ ,  $w_2 = 1, 1$ .
  3.  $F_3 = \neg Fr(x, y) \vee \neg Sm(x) \vee Sm(y)$ ,  $w_3 = 1, 1$ .
- ▶ Constantes  $C = \{Anna, Bob\}$ .



## Recordamos el problema de inferencia

- ▶ Sean  $F_1$  y  $F_2$  conjunciones de *ground literals*.
- ▶ Problema de inferencia: ¿Cuál es la prob. de  $F_1$  dado que vale  $F_2$ ?:

$$P(F_1|F_2) = \frac{\sum_{x \in \mathcal{X}_{F_1} \cap \mathcal{X}_{F_2}} P(X = x)}{\sum_{x \in \mathcal{X}_{F_2}} P(X = x)}$$

- ▶ Esto no se puede calcular ni a palos (NP-completo), aunque sea todo finito. Tampoco  $P(X = x)$ .
- ▶ Se puede aproximar muestreando  $X$  tales que cumplen  $F_2$  y viendo cuántos cumplen también  $F_1$  (método de Monte Carlo).



# Monte Carlo con cadenas de Markov (MCMC)

- ▶ Una forma de obtener una muestra es simulando una cadena de Markov  $X^0, X^1, \dots$  cuya dist. estacional sea  $P(X = x)$ .
- ▶ Hagamos  $\pi_x = P(X = x)$  y  $p_{xy} = P(X^{t+1} = y | X^t = x)$ .
- ▶ Un teorema dice que si

$$\pi_x p_{xy} = \pi_y p_{yx}$$

entonces  $\pi$  es la dist. estacional de la cadena  $p_{yx}$ .

- ▶ Suele ser fácil encontrar cadenas para muestrear cualquier  $P(X = x)$ .
- ▶ Un ejemplo de MCMC es el algoritmo de Metropolis-Hastings, y en particular el muestro de Gibbs.

# Muestreo de Gibbs: Definición

- ▶ Para obtener muestras de  $P((X_1, \dots, X_n) = (x_1, \dots, x_n))$  usando la dist. condicional de cada variable.
- ▶ Es un MCMC. Algoritmo para obtener  $x^{t+1}$  de  $x^t$ :
  1. Elegir  $j \in \{1, \dots, n\}$  al azar.
  2. Elegir  $x_j$  con prob.  $P(X_j = x_j | X_k = x_k^t, k \neq j)$ .
  3.  $x^{t+1} = x_{[j \leftarrow x_j]}^t$ .
- ▶ Formalmente,

$$p_{xy} = \begin{cases} \frac{1}{n} P(X_j = y_j | X_k = y_k, k \neq j) & \text{si } \forall k \neq j : y_k = x_k \\ 0 & \text{c.c.} \end{cases}$$

- ▶ Si  $\pi_x = P(X = x)$ , se puede probar que

$$\pi_x p_{xy} = \pi_y p_{yx}$$

- ▶ Esquema de la prueba: si  $\forall k \neq j : y_k = x_k$ ,

$$\begin{aligned}\pi_x p_{xy} &= P(X = x) \frac{1}{n} P(X_j = y_j | X_k = y_k, k \neq j) \\ &= P(X = x) \frac{1}{n} \frac{P(X = y)}{\sum_{z: z_k = x_k, k \neq j} P(X = z)} \\ &= \dots \\ &= \pi_y p_{yx}\end{aligned}$$

- ▶ Dijimos

$$P(X = x) = \frac{1}{Z} \exp\left(\sum_i w_i n_i(x)\right)$$

- ▶ Tenemos que calcular  $P(X_j = x_j | X_k = x_k, k \neq j)$ .
- ▶ Ahora,

$$P(X_j = x_j | X_k = x_k, k \neq j) = P(X_j = x_j | B_j = b_j)$$

a donde  $B_j$  es la colcha de Markov de  $X_j$ .

- ▶ Es decir,  $X_j$  sólo depende de sus nodos vecinos en la *Markov Network*.

- ▶ Sea  $F_j$  el cjto. de *groundings* de fórmulas que tienen a  $X_j$ .
- ▶ Si  $f \notin F_j$ , su valor de verdad no depende de  $X_j$ .
- ▶ Si  $f \in F_j$ , su valor de verdad **sólo** depende de  $X_j$  y  $B_j$ .
- ▶ Esquema de la prueba:

$$\begin{aligned} P(X_j = x_j | X_k = x_k, k \neq j) &= \frac{P(X = x)}{P(X = x_{j \leftarrow 0}) + P(X = x_{j \leftarrow 1})} \\ &= \frac{\exp(\sum_i w_i n_i(x))}{\exp(\sum_i w_i n_i(x_{j \leftarrow 0})) + \exp(\sum_i w_i n_i(x_{j \leftarrow 1}))} \\ &= \dots \\ &= \frac{\exp(\sum_{f \in F_j} w_f f(x_j, b_j))}{\exp(\sum_{f \in F_j} w_f f(0, b_j)) + \exp(\sum_{f \in F_j} w_f f(1, b_j))} \\ &= P(X_j = x_j | B_j = b_j) \end{aligned}$$

## Ok, un ejemplo:

- ▶  $X_j = \text{Friends}(B, A)$  y  $B_j = (\text{Smokes}(A), \text{Smokes}(B))$ .
- ▶ Calculemos  $P(X_j = x_j | B_j = b_j)$  si  $b_j = (1, 0)$ .
- ▶ Los groundings en los que aparece  $\text{Friends}(B, A)$  son:
  1.  $F_2(B, A) = \neg \text{Fr}(B, A) \vee \text{Sm}(B) \vee \neg \text{Sm}(A)$ ,  $w_2 = 1, 1$ .
  2.  $F_3(B, A) = \neg \text{Fr}(B, A) \vee \neg \text{Sm}(B) \vee \text{Sm}(A)$ ,  $w_3 = 1, 1$ .
- ▶ Luego
  1.  $P(X_j = 0 | B_j = b_j) = \frac{\exp(2,2)}{\exp(2,2) + \exp(1,1)}$
  2.  $P(X_j = 1 | B_j = b_j) = \frac{\exp(1,1)}{\exp(2,2) + \exp(1,1)}$

