

# ALGORITMOS APROXIMADOS Y EXACTOS PARA ESTRUCTURAS PICTÓRICAS



Sebastián Ubalde  
subalde@dc.uba.ar

Norberto A. Goussies  
ngoussie@dc.uba.ar

Marta E. Mejail  
marta@dc.uba.ar

Departamento de Computación – Facultad de Ciencias Exactas y Naturales  
Universidad de Buenos Aires

## Introducción

Trabajamos sobre la idea de representar un objeto como un conjunto de partes organizadas en una configuración deformable. Este tipo de modelo recibe el nombre de **estructura pictórica**.



## Modelo

Una estructura pictórica es un **grafo**  $G = (V, E)$  donde los vértices  $V$  corresponden a las partes y los ejes  $E$  corresponden a las conexiones entre partes.

Una instancia de objeto se especifica mediante una **configuración**  $L = (l_1, \dots, l_2)$  donde  $l_i$  especifica la ubicación de  $v_i$  para cada  $v_i \in V$ .

Dada una imagen  $I$ , buscamos un  $L$  que ubique satisfactoriamente el objeto modelado en la misma.

Hacemos un **planteo probabilístico** del problema:

$$p(L|I, \theta) \propto p(I|L, \theta)p(L|\theta)$$

Donde  $\theta = (u, E, c)$  son los parámetros del modelo.

Además, modelamos:

$$p(I|L, \theta) = p(I|L, u) \prod_{i=1}^n p(I|l_i, u_i)$$

$$p(L|\theta) = p(L|E, c) = \prod_{(v_i, v_j) \in E} p(l_i, l_j | c_{ij})$$

Obteniendo, por lo tanto:

$$p(L|I, \theta) \propto \left( \prod_{i=1}^n p(I|l_i, u_i) \prod_{(v_i, v_j) \in E} p(l_i, l_j | c_{ij}) \right)$$

## Aprendizaje del Modelo

Dadas las imágenes  $\{I^1, \dots, I^m\}$  y sus correspondientes configuraciones  $\{L^1, \dots, L^m\}$ . Buscamos los parámetros del modelo  $\theta = (u, E, c)$ . Usando **Máxima Verosimilitud** tenemos que maximizar:

$$\theta^* = \arg \max_{\theta} \prod_{k=1}^m p(I^k | L^k, \theta) \prod_{k=1}^m p(L^k | \theta)$$

Los **parámetros de apariencia** pueden ser **maximizados** en forma **independiente**:

$$u_i^* = \arg \max_{u_i} \prod_{k=1}^m p(I^k | l_i^k, u_i)$$

Los **parámetros de conexión** pueden ser **maximizados** incluso sin conocer sin saber cuáles serán parte de  $E$ ,

en forma **independiente**:

$$c_{ij}^* = \arg \max_{c_{ij}} \prod_{k=1}^m p(l_i^k, l_j^k | c_{ij}^*)$$

Definimos la **calidad de una conexión** como:

$$q(v_i, v_j) = \prod_{k=1}^m p(l_i^k, l_j^k | c_{ij}^*)$$

Finalmente, usamos **árbol generador máximo** para buscar encontrar las conexiones de **mejor calidad**:

$$E^* = \arg \max_E \prod_{(v_i, v_j) \in E} q(v_i, v_j)$$

## Inferencia Exacta

Buscamos la configuración que mejor ubica al objeto en la imagen. Es decir, buscamos resolver el siguiente problema de **minimización**:

$$L^* = \arg \min_L \left( \sum_{i=1}^n -\log p(I|l_i, u_i) \sum_{(v_i, v_j) \in E} -\log p(l_i, l_j | c_{ij}) \right)$$

La **minimización es NP-Hard** en general. Sin embargo, si **E es un árbol** se puede utilizar **programación dinámica**.

Se puede ver que las ecuaciones que se obtienen son:

$$l_r^* = \arg \min_{l_r} \left( -\log p(I|l_r, u_j) + \sum_{v_c \in C_j} B_c(l_j) \right)$$

$$B_j(l_i) = \min_{l_j} \left( -\log p(I|l_j, u_j) - \log p(l_i, l_j | c_{ij}) + \sum_{v_c \in C_j} B_c(l_j) \right)$$

La complejidad temporal es entonces  $\mathcal{O}(nH)$  donde  $H$  es el tiempo necesario para calcular  $B_j(l_i)$ . Si se usa la definición de  $B$  para su cálculo obtenemos que  $H \in \mathcal{O}(|L|^2)$ . Sin embargo, usando **algoritmos basados en la transformada distancia**:

$$D_f(x) = \min_{y \in \mathcal{G}} (\rho(x, y) + f(y))$$

Se puede obtener un algoritmo **lineal**.

## Inferencia Aproximada

- 1: calcular  $p(l_r | I, \theta)$
- 2: **push**(Q,r)
- 3: **while** no este vacía Q
- 4: k := pop(Q)
- 5: **muestrear** de  $p(l_k | l_{\pi_k}, I, \theta)$
- 6: **para cada** hijo i de k en E
- 7: **push**(Q,i)

Una posible forma de calcular  $p(l_r | I, \theta)$  es usando **marginalización**:

$$p(l_r | I, \theta) = \sum_{l_1} \sum_{l_{r-1}} \sum_{l_{r+1}} \sum_{l_n} \left( \prod_{i=1}^n p(I|l_i, u_i) \prod_{(v_i, v_j) \in E} p(l_i, l_j | c_{ij}) \right)$$

El problema con este enfoque es que requiere **tiempo exponencial**. Sin embargo, como **E es un árbol**, lo anterior se puede re-escribir:

$$p(l_r | I, \theta) \propto p(I|l_r, u_r) \prod_{v_c \in C_r} S_c(l_r)$$

Con  $S$  **definidas** como:

$$S_j(l_i) \propto \sum_{l_j} \left( p(I|l_j, u_j) p(l_i, l_j | c_{ij}) \prod_{v_c \in C_j} S_c(l_j) \right)$$

Para el paso 5 del algoritmo, es necesario calcular la función de densidad antes de muestrear. Para eso, se tiene en cuenta que:


$$p(l_j | l_j, I, \theta) \propto p(I|l_j, u_j) p(l_i, l_j | c_{ij}) \prod_{v_c \in C_j} S_c(l_j)$$

El cómputo de las funciones  $S$  se puede acelerar expresándolas como **convoluciones con una función Gaussiana** y usando que las mismas son separables.


## Aplicación: Caras

Modelo de apariencia:  $p(I|l_i, u_i) \propto \mathcal{N}(\alpha(l_i), \mu_i, \Sigma_i)$







Modelo de conexiones:  $p(l_i, l_j | c_{ij}) = \mathcal{N}(l_i - l_j, s_{ij}, \Sigma_{ij})$



Estructura aprendida con 5 partes




Estructura aprendida con 7 partes



## Aplicación: Cuerpo humano

Modelo de ubicación:

$$l = (x, y, s, \theta)$$




Modelo de conexiones:

$$p(l_i, l_j | c_{ij}) = \mathcal{N}(x'_i - x'_j, 0, \sigma_x^2) \mathcal{N}(y'_i - y'_j, 0, \sigma_y^2) \mathcal{N}(s_i - s_j, 0, \sigma_s^2) \mathcal{M}(\theta_i - \theta_j, \theta_{ij}, \kappa)$$



Cálculo de la posición de las juntas:

$$\begin{bmatrix} x'_i \\ y'_i \end{bmatrix} = \begin{bmatrix} x_i \\ y_i \end{bmatrix} + s_i R_{\theta_i} \begin{bmatrix} x_{ij} \\ y_{ij} \end{bmatrix}$$

$$\begin{bmatrix} x'_j \\ y'_j \end{bmatrix} = \begin{bmatrix} x_j \\ y_j \end{bmatrix} + s_j R_{\theta_j} \begin{bmatrix} x_{ji} \\ y_{ji} \end{bmatrix}$$



Estructura aprendida



## Referencias

- [1] P. F. Felzenszwalb and D.P. Huttenlocher. Pictorial structures for object recognition. *Int. J. Computer Vision*, 61(1), January 2005.
- [2] M.A. Fischler and R.A. Elschlager. The representation and matching of pictorial structures. *IEEE Transactions on Computers*, 22(1):67-92, January 1973.
- [3] D. Ramanan and C. Sminchisescu. Training deformable models for localization. *IEEE Conference on Computer Vision and Pattern Recognition*, 2006.
- [4] Y. Yang, D. Ramanan. Articulated Pose Estimation using Flexible Mixtures of Parts. *Computer Vision and Pattern Recognition*. June 2011.